

# Identifikation von Verkehrslasten unter Einsatz von Methoden des Soft Computing

Der Fakultät für Ingenieurwissenschaften,  
Abteilung Bauwissenschaften  
der Universität Duisburg-Essen  
zur Erlangung des akademischen Grades eines  
Doktor-Ingenieurs (Dr.-Ing.)  
vorgelegte und genehmigte

## DISSERTATION

von  
**Dipl.-Ing. Peer Lubasch**  
aus Laufenselden im Taunus

Essen 2009

## **Dipl.-Ing. Peer Lubasch**

Geboren 1977 in Bad Schwalbach im Taunus. Von Oktober 1998 bis Juli 2003 Studium des Bauingenieurwesens an der Technischen Universität Darmstadt. In den Jahren 2001 und 2002 zweisemestriges Auslandsstudium an der University of California at Berkeley, U.S.A. (DAAD-Stipendium). Nach Beendigung des Studiums bis Dezember 2004 Projektingenieur im Ingenieurbüro Kleinhofen und Schulenberg in Darmstadt. Von Januar 2005 bis März 2008 wissenschaftlicher Mitarbeiter am Institut für Massivbau der Universität Duisburg-Essen. Seit Mai 2008 erneut für das Büro Kleinhofen und Schulenberg tätig.

Hauptreferent:	Univ.-Prof. Dr.-Ing. Martina Schnellenbach-Held
Korreferenten:	Univ.-Prof. Dr.-Ing. Jürgen Grünberg Prof. Dr.-Ing. habil. Wilhelm Buschmeyer
Tag der Einreichung:	02.02.2009
Tag der mündlichen Prüfung:	24.03.2009

# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Massivbau der Universität Duisburg-Essen.

Frau Univ.-Prof. Dr.-Ing. Martina Schnellenbach-Held danke ich herzlich für die Betreuung und Förderung dieser Arbeit sowie die in jeder Hinsicht gewährte Unterstützung während meiner gesamten Tätigkeit.

Herrn Univ.-Prof. Dr.-Ing. Jürgen Grünberg danke ich sehr für die freundliche Übernahme des Korreferats und für sein deutliches Interesse an meiner Arbeit.

Herrn Prof. Dr.-Ing. habil. Wilhelm Buschmeyer danke für die Übernahme des Korreferats, die jederzeit gewährte Unterstützung und seine stetige Bereitschaft zu fachlichen Diskussionen.

Mein herzlicher Dank gilt den Kolleginnen und Kollegen. Für die fachlichen Diskussionen und freundschaftliche Zusammenarbeit möchte ich insbesondere Mark Freischlad und Torben Pullmann danken. Stellvertretend für das Institut sei Oliver Geibig und Markus Aldejohann für die entstandenen Freundschaften und die kollegiale Zusammenarbeit gedankt.

Meinen Eltern bin ich sehr dankbar für ihre Unterstützung und den Rückhalt während der letzten Jahre. Ganz besonders danke ich meiner Frau Nina Lubasch sowie unseren Kindern Paul und Anna für das aufgebrachte Verständnis und – nicht zuletzt – für ihre Ablenkung.

Meinen Dank möchte ich auch dem Bundesministerium für Verkehr, Bau und Stadtentwicklung (BMVBS) und der Bundesanstalt für Straßenwesen (BASt) aussprechen. Die eigenen Entwicklungen konnten im Rahmen des durch das BMVBS beauftragten und die BASt betreuten Forschungs- und Entwicklungsvorhabens 15.0388/2003/GRB an einem realen Brückenbauwerk validiert werden.



# Inhaltsverzeichnis

<b>Kapitel 1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Motivation .....	1
1.2	Stand der Forschung .....	3
1.2.1	Verkehrslastermittlung.....	3
1.2.2	Lösungsansätze für inverse Probleme des Ingenieurwesens .....	5
1.2.3	Lastidentifikation .....	6
1.3	Zielsetzung und Aufbau der Arbeit .....	10
<b>Kapitel 2</b>	<b>Methoden des Soft Computing</b>	<b>13</b>
2.1	Soft Computing.....	13
2.2	Evolutionäre Algorithmen .....	14
2.2.1	Allgemeines .....	14
2.2.2	Genetische Algorithmen .....	20
2.2.3	Evolutionsstrategien.....	20
2.2.4	Genetische Programmierung.....	21
2.3	Künstliche Neuronale Netze .....	29
2.3.1	Allgemeines .....	29
2.3.2	Singlelayer-Perceptrons .....	34
2.3.3	Multilayer-Perceptrons .....	35
<b>Kapitel 3</b>	<b>Identifikation von Verkehrslasten – IIM</b>	<b>37</b>
3.1	Allgemeines .....	37
3.2	Tragwerksreaktionen der Lastidentifikation.....	38
3.3	Vorgehensweise der Lastidentifikation .....	44
3.4	Analyse globaler Tragwerksreaktionen .....	47
3.4.1	Voraussetzungen.....	47
3.4.2	Initialisierung .....	49
3.4.3	Evolutionäre Operatoren.....	52
3.4.4	Lokale Reparaturen, Fitnesswertermittlung und Selektion.....	53

3.5	Analyse lokaler Tragwerksreaktionen.....	54
3.5.1	Voraussetzungen .....	54
3.5.2	Achsdetektion mit Hilfe künstlicher Neuronaler Netze .....	56
3.5.3	Initialisierung .....	60
3.5.4	Evolutionäre Operatoren .....	66
3.5.5	Lokale Reparaturen, Fitnesswertermittlung und Selektion .....	66
3.6	Zusammenführung der entwickelten Methoden.....	68
3.6.1	Allgemeines.....	68
3.6.2	Wesentliche Elemente: Funktionalitäten und Eigenschaften .....	68
3.6.3	Prinzipieller Ablauf der Messdatenanalyse.....	71
<b>Kapitel 4</b>	<b>Implementierung</b>	<b>75</b>
4.1	Übersicht, Voraussetzungen.....	75
4.2	Daten-Vorhaltung und -Aufbereitung .....	76
4.3	Messdatenanalyse.....	81
4.4	Daten-Nachbereitung .....	82
<b>Kapitel 5</b>	<b>Evaluierung</b>	<b>83</b>
5.1	Grundlagen.....	83
5.2	Achsdetektion mit Hilfe künstlicher Neuronaler Netze .....	90
5.3	Analyse globaler Tragwerksreaktionen.....	97
5.3.1	Messdaten.....	97
5.3.2	Untersuchte Parameter .....	97
5.3.3	Ergebnisse .....	99
5.4	Analyse lokaler Tragwerksreaktionen.....	103
5.4.1	Messdaten.....	103
5.4.2	Untersuchte Parameter .....	103
5.4.3	Ergebnisse .....	105
5.5	Diskussion der Ergebnisse .....	109
<b>Kapitel 6</b>	<b>Anwendung</b>	<b>113</b>
6.1	Bauwerk, durchgeführte Messungen.....	113
6.1.1	Systemdaten .....	113
6.1.2	Voraussetzungen .....	115
6.2	Numerisches Rechenmodell.....	115
6.2.1	Voruntersuchungen, Belastungsversuche.....	115
6.2.2	Detailbetrachtungen, wirklichkeitsnahe Modellbildung .....	118

---

6.3 Genauigkeitsklassifikation.....	121
6.4 Ergebnisse der Verkehrslastermittlung.....	122
<b>Kapitel 7 Zusammenfassung und Ausblick</b>	<b>125</b>
7.1 Zusammenfassung .....	125
7.2 Ausblick.....	127
<b>Anhang A Berechnungsbeispiel</b>	<b>129</b>
<b>Anhang B Anwendungsbeispiel</b>	<b>133</b>
<b>Anhang C Boxplot</b>	<b>139</b>
<b>Literaturverzeichnis</b>	<b>141</b>





# Kapitel 1

## Einleitung

### 1.1 Motivation

Im Verlauf der letzten Jahrzehnte ist die Anzahl der Schwerfahrzeuge im Bundesfernstraßennetz signifikant gestiegen. Im Vergleich zu Ergebnissen der 1980er Jahre hat sich die Fahrzeuganzahl etwa auf den doppelten Wert erhöht [BuSL07]. Hinsichtlich der Anzahl an Zulassungsanträgen für genehmigungspflichtige Schwertransporte sind zugleich überproportionale Zuwächse zu verzeichnen [Naum02, NaFH05, SaBS06]. Zusätzlich zum generell gestiegenen Verkehrsaufkommen werden Überladungen von Schwerfahrzeugen häufig beobachtet [Naum02, VaHe05]. Unlängst standen die Einführung von neuen Fahrzeugkonzepten und die Anhebung der zulässigen Gesamtgewichte auf 50 t und mehr in der öffentlichen Diskussion [GKLR06, Naum06, GrHL07].

Prognosen über die Verkehrsentwicklung bis zum Jahr 2015 weisen einen Anstieg des Schwerverkehrs von bis zu 60 % gegenüber dem Jahr 2000 aus [Naum07, VDA06]. Da ein weiterer Ausbau des Straßennetzes nur noch eingeschränkt möglich ist, wird der zu erwartende Schwerverkehr vornehmlich durch eine intensivere Nutzung der bestehenden Infrastrukturobjekte bewältigt werden [Naum02]. Der Schwerpunkt der öffentlichen Investitionen wird sich dementsprechend von der Planung neuer auf die Erhaltung bestehender Bauwerke verlagern.

Ein erhöhter Erhaltungsaufwand wird insbesondere für die Brückenbauwerke im Zuge der Bundesfernstraßen erforderlich werden. Da der überwiegende Teil der Bauwerke aus der Phase des Wiederaufbaus in der Nachkriegszeit stammt, weisen die Objekte ein durchschnittliches Alter von 30-50 Jahren auf [NaFH05]. Der Brückenbestand ist von sehr hohem Anlagevermögen und von übergeordneter volkswirtschaftlicher Bedeutung.

Zur Gewährleistung der Stand- und Verkehrssicherheit sowie der Dauerhaftigkeit wird der Zustand der Bauwerke periodisch im Rahmen von normativ geregelten Prüfungen festgestellt, wobei die Bewertungen subjektiv geprägt sein können [BoBe03, SaBe05]. Offensichtlich geschädigte Bauwerke, über die unzureichende Informationen vorliegen oder deren Schäden nur schwierig zu quantifizieren sind, werden häufig konservativ bewertet und ggf. kostenintensiven Ertüchtigungsmaßnahmen unterzogen [BoBe03]. Objektive Aussagen über den Bauwerkszustand können mit Hilfe von Methoden des Structural Health Monitoring gewonnen werden [Peet00, SaBe05]. Im Rahmen von adäquaten Analyseverfahren werden hierbei Messungen, die am überwachten Bauwerk durchgeführt werden, zur Ermittlung des wirklichkeitsnahen Tragwerkszustandes ausgewertet.

Die objektive Zustandsbewertung erfordert stets die Kenntnis der vorhandenen Beanspruchung sowie der effektiv einwirkenden Lasten [RSRS05]. Eigen- und Ausbaulasten können ohne besondere Maßnahmen hinreichend genau abgeschätzt werden. Die Bestimmung der tatsächlichen Verkehrslasten geht jedoch mit einem bedeutend höheren Aufwand einher [MeSe95, FFKM96, CuLP05, RSRS05, HaGr06, MeHi06, NBBP07]. Zu deren Ermittlung können Methoden der Lastidentifikation eingesetzt werden.

Die Kenntnis der tatsächlichen Verkehrssituation hinsichtlich der einwirkenden Lasten hat neben der sachgemäßen Bauwerksbeurteilung unter anderem folgenden Nutzen:

- Planung zukünftiger Infrastrukturobjekte: Anpassung der relevanten technischen Regelwerke an geänderte Verhältnisse
- Erfassung von Achslasten: Überhöhte Achslasten schädigen den Straßenbelag übermäßig und verursachen hohe wirtschaftliche Folgeschäden
- Strafverfolgung überladener Fahrzeuge: Gewährleistung der Verkehrssicherheit bei Durchsetzung gesetzlicher Vorschriften, zudem Sicherstellung der Wettbewerbsgleichheit der Spediteure
- Zielgerichtete Zuweisung von budgetierten und begrenzten Haushaltsmitteln, ggf. im Rahmen eines generellen Verkehrsmanagements

Eine geschlossene Lösung zur automatisierten Verkehrslastermittlung, die in Kombination mit einem Überwachungssystem zur frühzeitigen Schadensfeststellung eingesetzt werden kann, verspricht die Unterstützung der objektiven Zustandsbewertung, die Senkung von Erhaltungskosten und folglich die Verlängerung der Nutzungsdauern. Die Entwicklung eines derartigen Ansatzes, dessen Implementierung und Validierung anhand eines praxisrelevanten Beispiels sind die Intentionen der vorliegenden Arbeit.

## 1.2 Stand der Forschung

### 1.2.1 Verkehrslastermittlung

Methoden der Lastermittlung können allgemein in zwei Kategorien unterteilt werden: Die direkten und die indirekten Methoden. Direkte Methoden bestimmen eine gesuchte Lastgröße mit Hilfe geeigneter Messinstrumente, die am Lastangriffspunkt eingesetzt werden. Indirekte Methoden analysieren eine Strukturantwort hinsichtlich der verursachenden Lasten und ermitteln sowohl deren Größen als auch die Angriffspunkte.

Zum Erhalt von statischen Fahrzeuglasten und -varianten unter regulären Verkehrsbedingungen wurden Weigh-in-Motion (WIM) Systeme entwickelt und angewendet [WAVE01a]. Ohne Störung des Verkehrsflusses wird das gesamte Verkehrsaufkommen erfasst. Die direkte Messung wird mit Hilfe von Systemen in oder auf dem Fahrbahnbelag vorgenommen, wohingegen die indirekte Messung mit Systemen an bestehenden Brückentragwerken erfolgt [Gonz01].

#### *Direkte Messung: Systeme in oder auf dem Fahrbahnbelag*

WIM-Systeme in oder auf dem Fahrbahnbelag verwenden Platten- oder Streifensensoren zur Bestimmung der Verkehrslasten. Grundsätzlich befinden sich die Sensoren in direktem Kontakt mit den darüber verkehrenden Rad- bzw. Achslasten. Die physikalischen Messprinzipien des Platten- und Streifensensors unterscheiden sich wie folgt: Während der Plattensensor bei einer Fahrzeugüberfahrt jeweils über die ganze Radaufstandsfläche belastet wird, erfährt der Streifensensor je Achse eine Belastung durch ein schmales Reifensegment. Beim Plattensensor werden die Lasten durch Messung direkt erhalten. Die Lastermittlung beim Streifensensor erfordert die Integration der aufgezeichneten Messsignale über die Zeit. Die erzielbare Genauigkeit ist hierbei in starkem Maße von der genauen vorherigen Abschätzung der Fahrzeuggeschwindigkeit abhängig. Aufgrund der Aufzeichnung und Auswertung von zeitlich sehr kurzen Signalen sind die Systeme sensitiv bezüglich Signalrauschens und Messungenauigkeiten. Streifensensoren weisen eine geringere Genauigkeit als Plattensensoren auf [IRD01]. Die Sensorkosten liegen jedoch deutlich unter denen eines Plattensensors [IRD01]. Durch die Nutzung mehrerer Streifensensoren, die in Fahrtrichtung hintereinander angeordnet werden, wurde die Genauigkeit deutlich verbessert [JaOB05]. Bei diesen Systemen werden die statischen Lasten üblicherweise durch Mitteln der einzelnen Sensorsignale bestimmt. Grundsätzlich müssen eingesetzte Sensoren eine extreme Robustheit und Dauerhaftig-

keit aufweisen, da sie sämtlichen Umwelteinflüssen (insbesondere Temperatur und Feuchte) sowie hohen mechanischen Ansprüchen (bspw. Schneepflüge und -ketten) direkt ausgesetzt sind [OpKu05].

Die unbekannte Fahrzeugdynamik (Art der Fahrzeugfederung und -dämpfung, tatsächlicher Reifendruck, etc.) stellt eine wesentliche Beeinträchtigung der Fahrbahn-Systeme dar. Dynamische Effekte infolge der Fahrzeug-Fahrbahn-Interaktion können beachtliche Abweichungen in den ermittelten statischen Lasten zur Folge haben [WAVE01a]. Der Einfluss und die Größenordnung dynamischer Effekte wurde in [LuBa99] untersucht: Auf Grund einer Bodenwelle vor einer Brücke wurden an einem instrumentierten Fahrzeug dynamische Radlasten gemessen, die das Zweifache der statischen Lasten betragen. Zur Minimierung derartiger Effekte und ihres Einflusses auf die Genauigkeit der Systeme ist ein ebener Fahrbahnbelag vor der Messstelle von hoher Bedeutung.

### ***Indirekte Messung: Systeme an bestehenden Brückentragwerken***

WIM-Systeme an bestehenden Brücken (B-WIM) nutzen das gesamte Bauwerk als Messinstrument. Im Rahmen einer Lastidentifikation werden erfasste Tragwerksreaktionen hinsichtlich der verursachenden Lasten analysiert. Zur Messdatenanalyse sind komplexe Algorithmen erforderlich, da die Überlagerung der Tragwerksreaktionen infolge mehrerer Fahrzeuge auf dem Bauwerk zu berücksichtigen ist [ŽnLK05].

In einzelnen Anwendungen haben B-WIM-Systeme eine hohe Genauigkeit erreicht. Aufgrund der Verkehrslastermittlung auf der Basis kontinuierlicher Tragwerksmessungen sind die Systeme wenig sensitiv bezüglich der unbekannten Fahrzeugdynamik bzw. dynamischer Effekte der Fahrzeug-Fahrbahn-Interaktion [WAVE01a]. Zur Messung werden im Allgemeinen handelsübliche Dehnungsmessstreifen und Wegaufnehmer eingesetzt. Herkömmliche Systeme verfügen über Achsdetektoren in der Fahrbahn. Der Einsatz von zwei Detektoren je Fahrspur ermöglicht hierbei die Bestimmung der Fahrzeuggeschwindigkeit, der Achslagen und in der Folge des Fahrzeugtyps. Systeme ohne jegliche Detektoren in oder auf der Fahrbahn (Free-of-Axle-Detector, FAD oder Nothing-On-the-Road, NOR) stellen eine Weiterentwicklung der traditionellen B-WIM-Systeme dar [ŽnLK05]: Die Dauerhaftigkeit der Systeme wird maßgeblich gesteigert, da keine Sensoren vorhanden sind, die der direkten Verkehrsbelastung ausgesetzt sind. Darüber hinaus werden Installations- und Wartungskosten gesenkt. Sowohl für FAD- als auch für NOR-Systeme werden die Fahrzeuggeschwindigkeit und die Achskonfigurationen durch die Analyse der Aufzeichnung von Sensoren, die an zweckmäßig ausgewählten Stellen am Bauwerk angebracht wurden, ermittelt.

Diese Form der Verkehrslastermittlung erfordert kontinuierliche Bauwerksmessungen. Brücken-WIM und -monitoring können daher gut kombiniert werden.

Mit dem Ziel der Entwicklung einer Methodik zur Ermittlung statischer Verkehrslasten, welche in einem Monitoringsystem zur Zustandsüberwachung von Brückenbauwerken integriert werden könnte, werden nachfolgend Methoden der Lastidentifikation betrachtet. Zunächst werden grundsätzliche Ansätze zur Lösung inverser Probleme des Ingenieurwesens dargestellt und die Lastidentifikation allgemein eingeordnet. Wesentliche Ansätze werden anschließend im Einzelnen erläutert.

### 1.2.2 Lösungsansätze für inverse Probleme des Ingenieurwesens

Eine reale Tragstruktur wird durch das theoretische Rechenmodell  $M$  abgebildet, das eine Last- ( $L$ ), System- ( $S$ ) und Reaktionskomponente ( $R$ ) gemäß des Tupels der nachfolgenden Gleichung berücksichtigt:

$$M = [L, S, R] \quad (1.1)$$

Die Systemkomponente beinhaltet hierbei Angaben bezüglich der geometrischen Repräsentation der Tragstruktur, der Lagerungsbedingungen, der Materialeigenschaften und systembezogener Parameter. Für ein mechanisch nichtlineares Problem sind die einzelnen Kenngrößen des Systems  $S$  von den einwirkenden Lasten  $L$  abhängig. Für ein lineares Problem ist  $S$  unabhängig von  $L$ .

Hinsichtlich der gesuchten Information werden direkte und inverse Aufgabenstellungen unterschieden [LiXW01, Uhl07]. Die direkten Probleme (auch: Vorwärtsprobleme) beschäftigen sich mit der Ermittlung der Tragwerksreaktion  $R$  bei bekanntem  $L$  und  $S$ . Für die inversen Probleme werden zwei Aufgabengebiete betrachtet: Die Lastidentifikation setzt sich mit Mechanismen zur Bestimmung von  $L$  bei gegebenem  $S$  und  $R$  auseinander, wohingegen die Systemidentifikation Methoden zum Erhalt von  $S$  bei Vorgabe von  $L$  und  $R$  untersucht.

Inverse Probleme gelten als schlecht-gestellt und besitzen in der Regel keine eindeutige Lösung. Für praxisrelevante Aufgaben kann meist keine analytisch geschlossene Lösung angegeben werden [Groe93, Uhl07].

Für einen Großteil der inversen Probleme des Ingenieurwesens sind die zugehörigen Vorwärtslöser verfügbar. In solchen Fällen kann das inverse Problem als direktes Problem mit unvollständiger Eingabeinformation aufgefasst werden [LiXW01]. Mit Hilfe

parametrisierter Rechenmodelle können derartige Probleme im Rahmen einer iterativen Anpassung der relevanten Kennwerte gelöst werden: Die Interpretation adaptierter Modelle ermöglicht den Rückschluss bezüglich der gesuchten Größen. Da der Vorwärtslöser üblicherweise isoliert eingesetzt wird, können nichtlineare Probleme direkt behandelt werden. Darüber hinaus ist die strikte Unterscheidung der Komponenten nach Gleichung 1.1 nicht mehr erforderlich. Dies ermöglicht die Lösung gemischter Aufgaben der Last- und Systemidentifikation. Die Modelladaption basiert in aller Regel auf einer Finite Elemente Struktur [Link00].

Alternativ zur Modelladaption lassen sich inverse Aufgaben des Ingenieurwesens auch durch die Abbildung der unbekannten Zusammenhänge in nachgeordneten Modellen lösen. Hierzu können Methoden der Statistik (bspw. Regressionsanalyse) oder der künstlichen Intelligenz (bspw. künstliche Neuronale Netze) eingesetzt werden. Als Black-Box-Systeme beschreiben die Modelle Beziehungen, die zwischen den Komponenten gemäß Gleichung 1.1 bestehen. Die Feststellung der maßgebenden System- oder Lastkenngrößen ist nur eingeschränkt möglich. Derartige Ansätze sind zur ingenieurmäßigen Lösung realer Praxisprobleme wenig geeignet.

### 1.2.3 Lastidentifikation

Zur Lastidentifikation können im Grundsatz zwei Herangehensweisen unterschieden werden: (1) Das Vorgehen über dynamische Bauwerksmessungen und eine Interpretation der dynamischen Charakteristik der Struktur und (2) die Aufzeichnung von Verformungen und Dehnungen und die anschließende statische Analyse.

Dynamische Ansätze nutzen insbesondere modale Systemeigenschaften (Eigenfrequenzen und -formen) und die Verläufe gewonnener Übertragungsfunktionen zur Lastidentifikation. Das Vorgehen über stark kondensierte Daten bringt den Vorteil der Datenkompression mit sich, geht jedoch mit Verlusten an Informationen über das Tragsystem einher [Muel03, HWSR07]. Niederfrequente Strukturschwingungen, die normalerweise verwendet werden, regen das System zur globalen Schwingung an. Auf Grund großer Wellenlänge verringert sich jedoch die Sensitivität bezüglich lokaler Effekte [Muel03, FaSR04, Frit05]. Die Abschätzung des Temperatureinflusses auf die Tragwerkssteifigkeiten ist nur mit Schwierigkeiten möglich [PeMD01, Felt02, FaSR04, Frit05]. Derartige Umwelteinflüsse können bei instationären Systemen die dynamischen Systemeigenschaften deutlich beeinträchtigen [Muel03]. Im Vorgehen verbleiben grundsätzlich Unsicherheiten in der Bewertung der Dämpfungsbeiwerte der Struktur [CaMo05, GeFl05].

Statische Ansätze werden in [Muel03] als zielführende Alternative zur Nutzung kondensierter Daten (bspw. der experimentellen Modalanalyse) benannt. Nach [GeFl05] stellen Dehnungen Tragwerksparameter „erster Ordnung“ dar, die unmittelbar den vorliegenden Beanspruchungszustand repräsentieren und direkt auf das Tragverhalten schließen lassen. In Untersuchungen an realen Massivbrücken zeigten statische Systemkenngrößen im Vergleich zu Änderungen in der dynamischen Systemcharakteristik die deutlich höhere Sensitivität [GeFl05, HCHF06].

Zur Lastidentifikation wurden in den vergangenen Jahren verschiedene Verfahren entwickelt. Nachfolgend werden die wichtigsten Ansätze vorgestellt und hinsichtlich ihres Bezugs zur vorliegenden Arbeit kritisch bewertet.

Moses präsentiert in [Mose79] den vermutlich ersten Ansatz zur Identifikation von Verkehrslasten durch die Analyse von Brückenmessungen. Zur Ermittlung der Fahrzeuglasten müssen die Fahrgeschwindigkeiten und Achsabstände bekannt sein. Das entwickelte teilautomatisierte Verfahren berücksichtigt nicht den Einfluss der lateralen Position der Fahrzeuge und gilt ausschließlich für lineare Systeme. Aus heutiger Sicht ist das Vorgehen als ungenügend zu bezeichnen.

D’Cruz und Crisp entwickeln in [DCCr90] einen analytischen Ansatz zur Bestimmung von Ort und Größe einer einzelnen Punktlast, die auf eine allseits gelenkig gelagerte Rechteckplatte einwirkt. Im numerischen Beispiel werden zur Lastidentifikation vier diskrete Messpunkte an der Platte simuliert. Ungenauigkeiten realer Messungen werden durch das Hinzufügen eines künstlichen Rauschens berücksichtigt. Das Beispiel ist sehr einfach und die Anwendung des entwickelten Ansatzes sehr stark begrenzt. Zur Übertragung auf allgemeine Strukturen, welche mehreren Lasten ausgesetzt sind, wird die Minimierung des quadrierten Fehlers aus gemessenen und berechneten Verformungsgrößen vorgeschlagen. Methoden der kleinsten Fehlerquadrate werden als sehr robust gegenüber verrauschten Messsignalen bezeichnet. Beispielhaft wird zur Lösung des Optimierungsproblems die Verwendung des Gauß-Newton-Verfahrens aufgezeigt. Der Algorithmus kann in lokalen Minima der Zielfunktion enden und ist daher für komplexe Aufgabenstellungen der Lastidentifikation wenig geeignet.

Uhl et al. schlagen in [UhPi01] und [UhPi03] die Verwendung eines einfachen Genetischen Algorithmus (GA) zur Lösung von Problemstellungen der Lastidentifikation vor. Die Zielfunktion stellt die Minimierung der Fehlerquadratsumme aus gemessenen und berechneten Tragwerksreaktionen dar. Die erforderlichen numerischen Berechnungen werden in einem separaten Finite Elemente Programmsystem durchgeführt. Es wird

festgestellt, dass ein derartiges Vorgehen zur globalen Lösung sowohl linearer als auch nichtlinearer mechanischer Probleme äußerst geeignet ist. Die gewählte numerische Repräsentation der Lösungskandidaten in Vektoren von konstanter Länge beschränkt jedoch den Ansatz in starkem Maße: Die Anzahl der Lasten und deren mögliche Angriffsorte müssen fix in den Vektoren definiert werden. Im sehr simplen numerischen Beispiel wird dies beispielhaft für eine Last mit zwei möglichen Angriffsorten dargestellt, im praktischen Beispiel sind die Anzahl der Lasten und deren Einwirkungspunkte bereits bekannt. Die Analyse kontinuierlich erfasster Messgrößen ist nicht möglich.

Rojas Flores et al. setzen in [RoCh04] ein hybrides Verfahren auf der Basis der Partikel Schwarm Optimierung (PSO) und der Sequentiellen Quadratischen Programmierung (SQP) zur Lastidentifikation ein. Die Zielfunktion wird durch die Differenz aus modalen Kennwerten und den zugehörigen Ergebnissen einer Finite Elemente Berechnung beschrieben. Die Anwendung wird anhand von zwei einfachen numerischen Beispielen demonstriert. Aufgrund der Verwendung der dynamischen Charakteristik ist das Vorgehen zur Übertragung auf reale Massivbrücken ungeeignet. Nichtsdestotrotz wird auch hier festgestellt, dass die Lastidentifikation geeignete Optimierungsmethoden erfordert, welche die Suche der globalen Extrema der Zielfunktion ermöglichen. PSO wird gezielt zu diesem Zweck eingesetzt. SQP dient im hybriden Ansatz zur Verfeinerung von gewonnenen Lösungen im Rahmen einer lokalen Suche.

Yang et al. verwenden in [YaWS05] ein auf Genetischer Programmierung (GP) basierendes Optimierungsverfahren zur Ermittlung der Anregungslasten dynamischer Systeme. Die GP wird gewählt, da diese als stochastisches Suchverfahren globale Extrema ermittelt. Im Vergleich zum GA ermöglicht die GP die „flexible Repräsentation der Lösungskandidaten“, die hinsichtlich ihrer Abbildungsgröße keinen Einschränkungen unterliegen. Die GP wird daher als zielführend zur Lösung komplexer Aufgaben der Lastidentifikation beschrieben. Die entwickelte Methodik ist aufgrund der Betrachtung dynamischer Systemeigenschaften für die Anwendung auf Massivbrücken ungeeignet.

Žnidarič et al. beschreiben in [WAVE01b] und [ŽnLK05] das entwickelte SiWIM-System. Aufbauend auf dem in [Mose79] vorgeschlagenen Algorithmus werden Fahrzeuglasten durch die Auswertung von Dehnungen, die an instrumentierten Brückenüberbauten gewonnen werden, ermittelt. SiWIM erfordert keine Installationen auf dem Bauwerk. Die Fahrzeuggeschwindigkeit und die Achsabstände werden zusätzlich zu den gesuchten Fahrzeuglasten im Rahmen eines Optimierungsverfahrens bestimmt. Das Optimierungsverfahren basiert auf der Powell-Methode und berücksichtigt die Minimierung einer Zielfunktion, welche die quadrierte Differenz aus berechneten und gemessenen



nen Tragwerksreaktionen betrachtet. Vergleichende Untersuchungen belegen [FeTe01], dass die Powell-Methode dazu neigt, in lokalen Extrema einer Fehlerfunktion zu enden. Um das Auffinden der globalen Minima zu unterstützen, werden im Rahmen umfangreicher Sensitivitätsstudien [WAVE01b] scharfe Zwangsbedingungen für die zu optimierenden Parameter definiert. Die dargelegten Grundlagen gelten ausschließlich für linear elastische Systeme. Ohne Rücksicht hierauf soll SiWIM zur Anwendung an verschiedensten Brückenbauwerken geeignet sein [ŽnLK05]. Die Methodik wurde bisher insbesondere bei Bauwerken mit geringen Spannweiten eingesetzt.

Wenzel et al. präsentieren in [WeFV05] und [WeVe08] das entwickelte System DyGeS („Dynamisches Gewichtserfassungs-System“). Zur Ermittlung von Verkehrslasten auf Brücken wird das Schwingungsverhalten der Tragwerke unter Umgebungseinflüssen (ambient) analysiert. Das Vorgehen erfordert die separate Ermittlung von Fahrzeuggeschwindigkeiten und beruht auf der Auswertung von aufgezeichneten Bauwerksbeschleunigungen infolge der Fahrzeuglasten. Da die Beschleunigungen stark von den Fahrzeuggeschwindigkeiten abhängen, ist die genaue Geschwindigkeitsermittlung von sehr hoher Bedeutung. Im Analyseverfahren werden die Beschleunigungssignale zweimal integriert und die erhaltenen dynamischen Verformungen (Schwingwege um die Nulllinie) im Rahmen eines eigens entwickelten Verfahrens in absolute Verformungen überführt. Die Ermittlung der absoluten Verformungen ist bauwerksspezifisch und unterliegt gewissen Ungenauigkeiten. Der Ansatz ist auf lineare Systeme beschränkt, da der Gewichtserfassung die Ergebnisse von Belastungsversuchen (vertikale Bauteilverformungen in Abhängigkeit von der Fahrzeuggeschwindigkeit und dem -gewicht) linear zu Grunde gelegt werden. Darüber hinaus liefert das entwickelte System lediglich eine Näherung der wirklichen Lasten: DyGeS bestimmt „Ereignisse“, welche ein oder mehrere Fahrzeuge umfassen, ein Gewicht und eine Geschwindigkeit aufweisen. Die Identifikation der einzelnen Fahrzeuge sowie die genaue Ermittlung von Gesamtgewicht und Achslasten sind nicht möglich.

Die nachfolgenden Ansätze nehmen eine Lastidentifikation mit Hilfe von künstlichen Neuronalen Netzen (NN) vor:

Gagarin et al. setzen in [GaFA94] Neuronale Netze zur Bestimmung von Fahrzeugattributen aus Brückenmessungen ein. In einem zweigegliederten Analyseverfahren wird ein erstes NN verwendet, um den Fahrzeugtyp zu erhalten. Im Anschluss dient ein zweites, fahrzeugetypspezifisches NN dazu, die Geschwindigkeit, Achslasten und -abstände zu ermitteln. Einen wesentlichen Schwachpunkt des Systems stellt die Einschränkung auf

einzelne Fahrzeugereignisse dar – zur Lastidentifikation darf sich ausschließlich ein Fahrzeug auf dem Brückenbauwerk aufhalten, was die praktische Anwendung des Ansatzes sehr stark begrenzt. Darüber hinaus ist eine extrem hohe Anzahl an Neuronalen Netzen erforderlich, um sämtliche Fahrzeugtypen abzudecken. Das Vorgehen ist sehr starr und ausgesprochen bauwerksspezifisch. Im Vergleich verschiedener Netzstrukturen konnten mit Hilfe von mehrschichtigen feedforward Architekturen akzeptable Ergebnisse erreicht werden.

Uhl verwendet in [Uhl02] Neuronale Netze zur Ermittlung von Kräften, die am Dämpfer des Hauptrotors eines Helikopters auftreten. In einem zweistufigen Vorgehen wird mit Hilfe von fünf gemessenen Größen (Flughöhe, horizontale Geschwindigkeit, Gier-, Nick- und Rollwinkel) die Lastidentifikation durchgeführt. Ein erstes NN dient zur Bestimmung eines Flugstatus. Insgesamt können 44 fix definierte Flugstadien festgestellt werden. Nachgeschaltete NNs werden zur Ermittlung der am Dämpfer wirkenden Kräfte verwendet. Entsprechend der Flugstadien sind hierzu 44 verschiedene NNs erforderlich. Die Herangehensweise unterliegt ausgesprochen starren Strukturen und ist sehr problemspezifisch. Die eingesetzten mehrschichtigen feedforward Netze mit sigmoider Aktivierungsfunktion und Backpropagation-Training zeigten jedoch eine vielversprechende Leistungscharakteristik in der Verarbeitung realer Messgrößen, dies insbesondere im Rahmen der „ersten“ Mustererkennung zur Feststellung des Flugstatus.

### 1.3 Zielsetzung und Aufbau der Arbeit

In der vorliegenden Arbeit soll unter Berücksichtigung der aufgeführten Schwächen bisheriger Methoden ein durchgängiger Ansatz zur Identifikation statischer Verkehrslasten auf der Basis gemessener Querschnittsdehnungen von Brückenüberbauten entwickelt werden. Vor dem Hintergrund stetig steigender Beanspruchungen der bestehenden Brücken soll die zu entwickelnde Methodik in Monitoringsysteme der kontinuierlichen Zustandsüberwachung integrierbar sein. Dieser Anforderung entsprechend werden die Verkehrslasten indirekt im Rahmen einer Lastidentifikation ermittelt: Mit Hilfe von adäquaten Optimierungsverfahren werden numerische Rechenmodelle auf am Bauwerk gemessene Größen adaptiert. Die Lastkomponente der Modelle beschreibt die zum Messzeitpunkt jeweils vorliegende Belastungssituation. Um globale Lösungen zu erhalten, werden Evolutionäre Algorithmen zur Optimierung eingesetzt. Künstliche Neuronale Netze werden hybrid eingebunden und sollen einen effizienten Optimierungsprozess unterstützen. Im Vorgehen wird die Robustheit gegenüber teilweise verrauschten

und ungenauen Messgrößen sowie die Gültigkeit des Ansatzes für lineare und nicht-lineare Systeme gewährleistet. Zur Auswertung von kontinuierlich erfassten Messgrößen werden geeignete Verfahren untersucht. Durch die gezielte Beschränkung auf die Tragwerksreaktionen, welche maßgeblich auf die einwirkenden Lasten schließen lassen, sollen der Einsatz einer minimalen Anzahl an Sensoren und eine effiziente Lastidentifikation ermöglicht werden. Die Messung soll mit Hilfe von handelsüblichen Dehnungsmessstreifen und wieder verwendbaren Wegaufnehmern, ohne Installationen in oder auf der Fahrbahn, erfolgen.

Der Aufbau der Arbeit orientiert sich an den beschriebenen Zielen. Im folgenden Kapitel 2 werden die erforderlichen Grundlagen der evolutionären Optimierungsverfahren und künstlichen Neuronalen Netze dargelegt. Im Kapitel 3 wird der entwickelte IIM (Identification-in-Motion) Algorithmus vorgestellt und erläutert. Kapitel 4 zeigt dessen prototypische Implementierung und weitere entstandene Softwareapplikationen, die zur Vorhaltung und Aufbereitung von erfassten Messdaten bzw. zur Nachbereitung von gewonnenen Ergebnissen erforderlich sind. Im Kapitel 5 werden die entwickelten Ansätze der Messdatenanalyse evaluiert. Im Rahmen von umfangreichen Parameterstudien werden die Einflussgrößen festgestellt, welche maßgeblich den Prozess der Lösungsfindung sowie die erzielbare Lösungsqualität der eingesetzten evolutionären Optimierungsverfahren und künstlichen Neuronalen Netze bestimmen. Kapitel 6 stellt das Potential der entwickelten Methodik anhand der Anwendung an einer realen Spannbetonbrücke dar. Im Kapitel 7 werden die Erkenntnisse zusammengefasst und weiterer Forschungsbedarf aufgezeigt.



## Kapitel 2

# Methoden des Soft Computing

### 2.1 Soft Computing

Soft Computing (SC) vereinigt biologisch motivierte Methoden der Informationsverarbeitung zur Verwirklichung robuster und kostengünstiger Lösungsverfahren für komplexe Problemstellungen der Realität [Zade94, Zade01]. Im Unterschied zum Hard Computing erfordern die Problemlöser keine exakten analytischen Modelle – vielmehr berücksichtigen die SC-Methoden bewusst die Verarbeitung ungenauer, unvollständiger und teilweise fehlerhafter Information, um hierdurch eine Verringerung der Granularität der Aufgabenstellung oder eine Aufweichung definierter Optimierungsziele zu ermöglichen [LiRW98]. Einbußen in der Lösungsgenauigkeit gehen mit immensen Zugewinnen an Flexibilität und Variabilität zur Bearbeitung gegebener Probleme, die mit konventionellen exakten Methoden bisher nicht oder nicht zufrieden stellend lösbar waren, einher.

Vorbilder der SC-Methoden sind leistungsstarke Problemlöser der belebten Natur. Diese umfassen insbesondere [Zade94, EiSm03, Lipp05]:

- Das menschliche Gehirn und
- den evolutionären Prozess, der letztlich das menschliche Gehirn hervorbrachte.

Die Übertragung auf rechnergestützte Lösungsstrategien führt unter anderem auf künstliche Neuronale Netze und Evolutionäre Algorithmen. Mit Hilfe künstlicher Neuronaler Netze werden die vernetzte Struktur natürlicher Gehirne imitiert, das Lernvermögen nachempfunden und nichtlineare Schlussfolgerungsmechanismen abgebildet [NaKK96, Zell03]. Evolutionäre Algorithmen verbessern Lösungskandidaten hinsichtlich einer definierten Problemstellung durch die Simulation der biologischen Evolution. Sie zählen zur Gruppe der stochastischen Suchverfahren und haben sich im Rahmen zahlrei-

cher Optimierungsaufgaben zur Ermittlung der globalen Extrema in komplexen Suchräumen als sehr geeignet erwiesen [Koza92, Koza94].

Im Soft Computing besteht nicht der Anspruch, die Ursprungssysteme physikalisch „korrekt“ zu modellieren. Zur Konstruktion von effizienten Problemlösern werden einzelne Techniken in Kombination und keineswegs in Konkurrenz eingesetzt [Zade01].


## 2.2 Evolutionäre Algorithmen

### 2.2.1 Allgemeines

Evolutionäre Algorithmen (EA) sind Optimierungs- und Verbesserungsalgorithmen, die Elemente der Darwinschen Evolutionstheorie für mathematische und ingenieurtechnische Fragestellungen nutzbar machen.

Gemäß Darwin [Da1859] streben in der biologischen Evolution die Individuen der Populationen nach Überleben und Reproduktion. Über Generationen erfolgt eine Anpassung und Verbesserung der Individuen hinsichtlich vorhandener Umgebungsbedingungen. Die Individuen werden hierzu Variation und Selektion unterzogen. Dem Paradigma „Survival of the Fittest“ folgend überleben und reproduzieren sich vornehmlich Individuen, die einen hohen Adaptionsgrad, eine hohe Fitness, aufweisen. Im Sinne stochastischer Suchverfahren werden in einem Evolutionären Algorithmus die Lösungskandidaten (= Individuen der Population) bezüglich eines festgelegten Gütekriteriums (= Fitness) im Rahmen eines iterativen Prozesses (= Generationen) im Hinblick auf eine definierte Problemstellung (= Umgebungsbedingungen) in geeigneter Weise verbessert (= Variation und Selektion) [Geye95, Gold89, BBJP03, EiSm03].

Das grundsätzliche Ablaufschema der Evolutionären Algorithmen kann der Abbildung 2.1 entnommen werden. Üblicherweise wird die erste Population von  $\mu$  Individuen zufällig generiert. Mit Hilfe einer Zielfunktion, der Fitnessfunktion, werden die Individuen bewertet und die Fitness ermittelt. Basierend auf den Ergebnissen wird die Selektion der Eltern durchgeführt. Individuen mit relativ besseren Fitnesswerten werden mit relativ höherer Wahrscheinlichkeit als Eltern gewählt. Die  $\lambda \geq \mu$  Nachkommen werden auf Grundlage der selektierten Individuen durch die Anwendung der evolutionären Variationsoperatoren der Rekombination und Mutation erstellt. Nach der Fitnesswertermittlung werden die fittesten  $\mu$  Individuen in die Population der Folge-Generation übertragen. Der Gesamtprozess wird über mehrere Generationen ausgeführt, bis schließlich ein definiertes Abbruchkriterium erfüllt wird.



**Abbildung 2.1:** Prinzipielles Ablaufschema Evolutionärer Algorithmen

Erste Untersuchungen zur Überführung des evolutionären Prozesses auf technische Systeme wurden Anfang der 1960er Jahren von Bremermann durchgeführt [Adam03, EiSm03]. Unabhängig voneinander wurden in den folgenden Jahren drei Implementierungen des grundsätzlichen Ansatzes verfolgt. Fogel et al. [FoOW66] entwickelten die Evolutionäre Programmierung, Holland [Holl75] die Genetischen Algorithmen und Rechenberg und Schwefel [Rech73, Schw81] die Evolutionsstrategien. In den 1990er Jahren wurden die drei Bereiche aufgrund ihrer Gemeinsamkeiten als eigenständige Dialekte unter dem Begriff der Evolutionären Algorithmen zusammengefasst [SDBF93, Whit01, EiSm03]. Zugleich wurde von Koza [Koza92] die Genetische Programmierung als weiteres Teilgebiet eingeführt.

Nachfolgend werden in Ergänzung zur Abbildung 2.1 die wesentlichen Komponenten, welche für die Dialekte der Evolutionären Algorithmen gleichermaßen gelten, erläutert.

### **Repräsentation**

In Evolutionären Algorithmen werden codierte Versionen der Lösungskandidaten behandelt. Die codierte Lösung wird als Genotyp bezeichnet, wohingegen die decodierte Lösung den Phänotyp beschreibt. Zur Erzielung eines effizienten Optimierungsprozesses ist die Wahl einer adäquaten Repräsentationsform von extrem hoher Bedeutung [Banz01, ZWSM06]. Mit der Festlegung der Repräsentationsform sind die Transformationsmechanismen zur Überführung der Genotypen in die Phänotypen und umgekehrt zu spezifizieren (Codierung und Decodierung).

Die verschiedenen EA-Dialekte werden üblicherweise anhand der jeweils gewählten Repräsentationsart charakterisiert. Die Tabelle 2.1 enthält eine Übersicht zu den wesent-

lichen Dialekten. Die Evolutionäre Programmierung wird nicht gesondert betrachtet, da deren heutige Form „annähernd identisch“ [Whit01] mit den Evolutionsstrategien ist. Historisch bedingt nutzen Genetische Algorithmen hauptsächlich eine binäre und Evolutionsstrategien eine reelle Repräsentation der Genotypen in Vektoren von meist konstanter Länge. Die Genetische Programmierung verwendet komplexere Strukturen, wie Ableitungsbäume, ohne Beschränkungen hinsichtlich der Abbildungslänge. Die Tabelle 2.1 zeigt unter anderem Besonderheiten der Selektion, Rekombination und Mutation der Dialekte. Diese EA-Komponenten werden nachfolgend erläutert.

**Tabelle 2.1:** Übersicht zu den wesentlichen Evolutionären Algorithmen

Merkmal	Genetische Algorithmen (GA)	Evolutionsstrategien (ES)	Genetische Programmierung (GP)
Repräsentation	binär oder reell, in Vektoren von meist fest vorgegebener Länge	reell, in Vektoren von meist fest vorgegebener Länge	Baumstrukturen, ohne Beschränkung der Abbildungslänge
Selektion	deterministisch oder zufällig	deterministisch	deterministisch oder zufällig
Rekombination	primärer Variationsoperator	sekundärer Variationsoperator, sofern verwendet	primärer/einziger Variationsoperator
Mutation	sekundärer Variationsoperator	primärer/einziger Variationsoperator	sekundärer Variationsoperator, sofern verwendet

### ***Fitnessfunktion und -wert***

Die Fitnessfunktion repräsentiert das wesentliche Element zur Definition der Anforderungen zur Lösung der Problemstellung. Mit ihrer Hilfe wird die Güte, der Fitnesswert  $e_{\text{fit}}(i)$ , des  $i$ -ten Lösungskandidaten ermittelt. Üblicherweise nimmt die Auswertung mehr als 99 % des gesamten EA-Rechenaufwands ein [EiSc02]. Im Sinne der biologischen Evolution werden Individuen von höherer Fitness bevorzugt. Die Übertragung auf rechnergestützte Problemlösungsstrategien führt somit auf Maximierungsprobleme. Die Überführung eines Maximierungs- in ein Minimierungsproblem stellt eine mathematisch triviale Aufgabe dar.

### ***Population***

In der Population werden mögliche Lösungen vorgehalten. Die Populationsgröße kennzeichnet die Anzahl der Individuen und wird üblicherweise mit  $\mu$  beziffert. Die Lösungsvielfalt, welche eine Population umfasst, wird als Diversität bezeichnet.



**Initialisierung**

Zur Initialisierung wird eine erste Population von Individuen erzeugt. Üblicherweise werden die Individuen stochastisch über den Suchraum verteilt. Der Initial-Population können bereits bekannte – gute – Lösungen „eingepft“ werden. In dieser Weise wird Vorwissen bezüglich der Problemstellung mit der Initialisierung berücksichtigt.

**Abbruchkriterium**

Der Optimierungsprozess wird bei Erreichen definierter Abbruchbedingungen terminiert. Übliche Kriterien sind: (i) Eine gegebene Anzahl von Generationen wurde durchlaufen, (ii) eine Anzahl von Fitnesswertermittlungen wurde durchgeführt, (iii) die Diversität der Population stagniert oder/und (iv) über einen festgelegten Zeitraum fand keine nennenswerte Fitnessverbesserung statt.

**Selektion**

Die Selektion fokussiert die Suche auf Bereiche von hoher Fitness und forciert hierdurch maßgeblich die Qualitätsverbesserung der Lösungskandidaten. Basierend auf den Fitnesswerten der Individuen werden Eltern zur Erzeugung der Nachkommen der Folge-Generation gewählt. Im Rahmen eines probabilistischen Vorgehens werden die Individuen von hoher Fitness mit erhöhter Wahrscheinlichkeit berücksichtigt. Um Diversität zu bewahren und nicht in lokalen Extrema festzufahren, wird auch den Individuen mit schlechterer Fitness eine geringe Selektionswahrscheinlichkeit zugewiesen.

Zur Lösung eines Maximierungsproblems können die Fitnesswerte der Individuen gemäß Gleichung 2.1 (i, j: Indizes einzelner Individuen) auf Werte  $e_{\text{fit,norm}}$  normiert werden. Die Größe  $n_{\text{sel}}$  beschreibt die Selektionspotenz. Mit  $n_{\text{sel}} \geq 1,0$  wird die Wahrscheinlichkeit erhöht, „gute“ Individuen zur Generierung der Nachkommen heranzuziehen.

$$e_{\text{fit,norm}}(i) = \left( \frac{e_{\text{fit}}(i) - \min[e_{\text{fit}}(j)]_{j=1}^{\mu}}{\max[e_{\text{fit}}(j)]_{j=1}^{\mu} - \min[e_{\text{fit}}(j)]_{j=1}^{\mu}} \right)^{n_{\text{sel}}} \quad (2.1)$$

Die fitness-proportionale Selektion (Rouletterad-Selektion) repräsentiert einen sehr häufig eingesetzten Operator [EiSc02]. Die Selektionswahrscheinlichkeit  $p_{\text{sel}}(i)$  eines Individuums wird ermittelt, indem der jeweilige Fitnesswert ins Verhältnis zur Fitness der restlichen Population gesetzt wird (siehe Gleichung 2.2). Da der Wert  $p_{\text{sel}}(i)$  proportional zur Fitness des Individuums ist, bestimmen herausragende Individuen unter Um-

ständen nach Durchlauf einiger Generationen die Population – die Individuen gleichen sich einander an. Da sich in diesem Fall die Fitnesswerte der Individuen kaum unterscheiden, verringert sich der Selektionsdruck. Die zugewiesenen Anteile auf dem Rouletterad würden für die Individuen eine jeweils ähnliche Größe aufweisen. Der Algorithmus konvergiert gegebenenfalls vorzeitig gegen nichtoptimale Lösungen.

$$p_{\text{sel}}(i) = e_{\text{fit,norm}}(i) / \sum_{j=1}^{\mu} e_{\text{fit,norm}}(j) \quad (2.2)$$

Um die aufgeführten Nachteile im Selektionsdruck zu vermindern, wurden die Rang- und die Turniersélection entwickelt. Die Rangselektion berücksichtigt einen konstanten Selektionsdruck. Die Individuen werden entsprechend der Fitness sortiert, in einer geordneten Rangliste vermerkt und erhalten eine Selektionswahrscheinlichkeit auf Basis des Rangplatzes. Die Turniersélection wählt zur Bestimmung eines Elters  $k$  Individuen rein zufällig und selektiert das beste Individuum der Gruppe. Über die Turniergröße  $k$  kann hierbei der Selektionsdruck indirekt beeinflusst werden.

### ***Variation***

Der Rekombinationsoperator (auch: Kreuzungsoperator) tauscht Informationen der gewählten Eltern zur Generierung eines Nachkommens. Ziel ist es, vorteilhafte Eigenschaften der Eltern im Nachkommen zusammenzuführen. Insbesondere die Vererbung zusammenhängender genetischer Bausteine (engl.: Building Blocks), die Teillösungen (Substrukturen) darstellen, kann zu günstigen Kombinationen der Substrukturen führen und eine Annäherung an das Gesamtoptimum erwirken. Der Operator kann zur Exploration von bisher nicht betrachteten Regionen des Suchraums beitragen.

Der Mutationsoperator modifiziert einzelne Gene der genotypischen Repräsentation im Nachkommen. Die Mutation gewährleistet maßgeblich die Diversität der Population und stellt zugleich sicher, dass die Suche nicht in lokalen Extrema endet. Der Operator soll vornehmlich geringe Veränderungen an den Nachkommen vornehmen. Zu große Veränderungen würden vorhandene, gute Lösungen in zu starkem Maße abändern [EiSc02]. Der Operator unterstützt die Exploitation von Nachbarschaftsbereichen bereits bekannter guter Lösungen.

Domänenwissen kann mit der Durchführung zielgerichteter Operationen im Rahmen der Rekombination und Mutation berücksichtigt werden.

***Bildung der Population der Folge-Generation***

Zur Bildung der Population der Folge-Generation stehen  $\mu$  Individuen der aktuellen Generation und deren  $\lambda$  Nachkommen zur Verfügung. Die Übertragung einer gegebenen Anzahl bester Individuen, an welchen keinerlei Veränderungen vorgenommen werden, wird als elitäre Selektion (Elitismus) bezeichnet.

***Parameteranpassung***

Der Suchprozess Evolutionärer Algorithmen durchläuft verschiedene Phasen [EiSc98]: Zu Beginn der EA-Suche findet vornehmlich Exploration statt – die Population weist hohe Diversität auf; es gilt, die viel versprechenden Regionen des Suchraums zu erforschen. Große Variationsweiten sind hierzu geeignet. Nach Erkundung des Suchraums gewinnt die Exploitation an Bedeutung – die Population konzentriert sich um Spitzen der Fitnesslandschaft. In dieser Phase sind kleine Variationen von Vorteil.

Evolutionäre Algorithmen weisen eine Vielzahl an Parametern auf (insbesondere Populationsgröße und Rekombinations- sowie Mutationswahrscheinlichkeiten). Die Modifizierung der Parameter während des Ablaufs kann die Anforderungen der EA-Phasen sowie der Exploration und Exploitation geeigneter erfüllen als die Verwendung fixer Parametereinstellungen. Die Angleichung der Individuen und die Abmilderung des Selektionsdrucks bei Verwendung der fitness-proportionalen Selektion können hierdurch gesteuert werden. Anspruchsvolle EA regeln daher die Parameter adaptiv in Abhängigkeit von der Anzahl durchgeführter Generationen bzw. Fitnesswertermittlungen oder abhängig von definierten Konvergenzkriterien [HiME97].

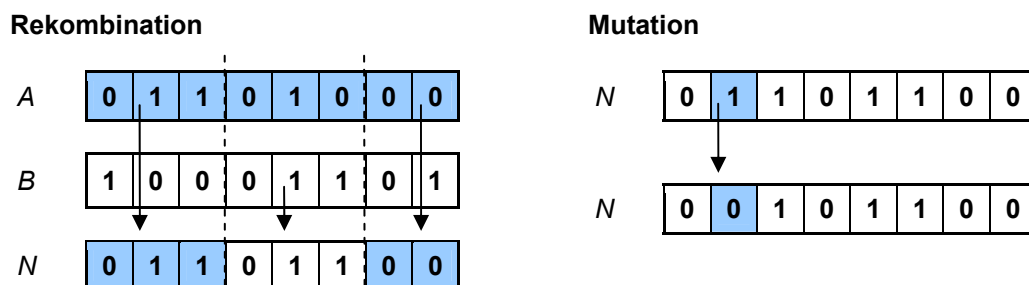
Bezüglich der EA-Komponenten kann eine Unterscheidung nach repräsentationsabhängigen und -unabhängigen Elementen getroffen werden. Repräsentationsabhängig sind die Mechanismen zur Genotyp/Phänotyp-Transformation und die Variationsoperatoren (Rekombination und Mutation). Repräsentationsunabhängig sind die Fitnesswertermittlung, die Selektion, die Bildung der Population der Folge-Generation und die Abbruchkriterien.

Zusammenfassend kann festgehalten werden, dass Domänenwissen insbesondere zur Erstellung der Initial-Population und mit der Anwendung der evolutionären Variationsoperatoren berücksichtigt werden kann.

### 2.2.2 Genetische Algorithmen

Genetische Algorithmen operieren in Analogie zum biologischen DNA-Alphabet auf Zeichenketten, insbesondere Binärketten von konstanter Länge [Gold89]. Ihr Ablauf folgt dem allgemeinen Schema der Abbildung 2.1, wobei üblicherweise  $\lambda = \mu$  Individuen behandelt werden. Bezüglich der Operatoren der Selektion und der Variation sind die Besonderheiten der Tabelle 2.1 zu entnehmen.

Für die Binärcodierung wird die prinzipielle Vorgehensweise der Rekombination und der Mutation anhand der Abbildung 2.2 demonstriert. Die Zwei-Punkt-Rekombination zweier Eltern  $A$  und  $B$  nach der dritten und sechsten Codestelle erzeugt im Beispiel den Nachkommen  $N$ . In der Mutation werden für  $N$  zufällig einzelne Codelemente negiert.



**Abbildung 2.2:** Binärcodierter GA: Evolutionäre Variationsoperatoren

Die Rekombinationspunkte werden in Genetischen Algorithmen rein zufällig gewählt. Hierdurch ist kaum vorhersehbar, ob gute Teillösungen (Building Blocks) erhalten bleiben oder zerstört werden. Obwohl die Rekombination den Haupt-Variationsoperator darstellt, kann sie zu einer bedeutenden Lösungsverschlechterung führen.

### 2.2.3 Evolutionsstrategien

Evolutionsstrategien verwenden im Allgemeinen reellwertige Repräsentationen der Lösungskandidaten, teilweise in der direkten Problemformulierung, welche die Unterscheidung der geno- und phänotypischen Abbildung nicht erfordert.

Die ES-Grundformen werden durch die  $(\mu/\rho\#\lambda)$  Nomenklatur charakterisiert [ScHF96]. Hierbei beschreibt  $\mu$  die Anzahl an Eltern und  $\lambda$  die Anzahl der Nachkommen. Es gilt  $\lambda \geq \mu \geq 1$ . Das Element  $\rho$  kennzeichnet die Anzahl der Eltern, welche einen Nachkommen generieren. Klassische Ansätze sehen die Erzeugung eines Nachkommens im Rahmen der Selbstverdoppelung der Individuen vor ( $\rho = 1$ ). Das „#“-Symbol steht stellvertretend für „+“ oder „“. Für  $\rho = 1$  wird verkürzt  $(\mu + \lambda)$  bzw.  $(\mu, \lambda)$  notiert.

Die Plus-Notation  $(\mu/\rho+\lambda)$  berücksichtigt die Bildung der Population der folgenden Generation aus den  $\mu$  Individuen der aktuellen Generation und deren  $\lambda$  Nachkommen. Da die besten Individuen aus Eltern und Nachkommen gewählt werden, kann sich keine Lösungsverschlechterung von Generation zu Generation einstellen (elitäre Selektion). Überragende Individuen, die über viele Generationen bestehen, können jedoch zur vorzeitigen Konvergenz gegen lokale Extrema führen. Evolutionsstrategien der Komma-Notation  $(\mu/\rho, \lambda)$  erstellen daher die Population der Folge-Generation ausschließlich aus den  $\lambda$  Nachkommen. Beim Übergang in die nächste Generation können jedoch Lösungsverschlechterungen nicht ausgeschlossen werden.

Die Elter-Selektion erfolgt rein zufällig – die Individuen werden unabhängig von ihrer Fitness mit jeweils gleicher Wahrscheinlichkeit gewählt. Der Selektionsdruck wird über den Quotienten  $\mu/\lambda$  gesteuert. Ein erhöhter Druck ergibt sich für einen geringen Wert des Quotienten (Fall  $\lambda \gg \mu$ ).

Die Rekombination ist von untergeordneter Bedeutung und wird, sofern berücksichtigt, für  $\rho \geq 2$  angewandt. Für das reellwertige Codeelement eines Nachkommens werden üblicherweise der zugehörige Wert eines Elters (diskrete Rekombination) oder ein gemittelter Wert aller Eltern (intermediäre Rekombination) übernommen [Adam03].

Die Mutation repräsentiert den primären evolutionären Operator. Der Operator basiert auf einer Gauß-Verteilung mit Mittelwert 0 und Standardabweichung  $\sigma$ . Die reellwertige Komponente  $x_i$  eines Vektors  $\vec{x}$  wird zu  $x_i'$  mutiert, indem eine normalverteilte Zufallszahl  $N(0, \sigma)$  addiert wird:  $x_i' = x_i + N(0, \sigma)$ . Die Gauß-Verteilung erfüllt die folgenden Anforderungen [Adam03]: (i) Verkleinerungen und Vergrößerungen von  $x_i$  erfolgen mit gleicher Wahrscheinlichkeit, (ii) der Erwartungswert, die mittlere Veränderung ist bekannt und (iii) die Mutationsweiten können über den Wert  $\sigma$  kontrolliert werden. Insbesondere die  $(\mu/\rho, \lambda)$ -Strategien setzen geringe Mutationsweiten ein, um sprunghafte Veränderungen möglichst zu vermeiden und Kontinuität im Übergang zur Folge-Generation zu gewährleisten. Die Mutation auf der Basis von definierten Wahrscheinlichkeitsverteilungen stellt ein leistungsstarkes Hilfsmittel zur kontrollierten Exploration und Exploitation des Suchraums dar [EiSc98].

### 2.2.4 Genetische Programmierung

Die Genetische Programmierung ist ein verhältnismäßig junges Teilgebiet der EA. Es entstand aus der Fragestellung heraus, ob es möglich sei, Computer Probleme lösen zu lassen, ohne diese explizit dafür zu programmieren [Koza92]. In der GP werden zur

automatisierten Programminduktion Genetische Algorithmen adaptiert. Der Einsatz der GP erfordert (i) eine Problemstellung, deren Lösung (Programm) computergestützt ausgewertet werden kann, (ii) eine adäquate Sprachdefinition und (iii) die Spezifikation einer hinreichend hohen Anzahl repräsentativer Test-Datensätze (zusammengehörige Eingabe-Ausgabe Paare) („The Genetic Programming Paradigm“, [Koza92]).

Im Unterschied zu GA und ES werden die GP-Genotypen nicht in binär- oder reellcodierten Vektoren von konstanter Länge abgebildet – vielmehr dienen zur Repräsentation interpretierbare Strukturen von variabler Länge ohne Einschränkungen hinsichtlich der Erscheinungsform. Die Genetische Programmierung bietet hierdurch extrem hohe Flexibilität und ein enormes Potential zur Lösung vielschichtiger Optimierungsprobleme [Banz01, EiSc02, ZWSM06]. Eine sehr häufige Herangehensweise stellt die Repräsentation der Individuen in Baumstrukturen dar [Bode04].

In der nachfolgenden Darstellung der Grundlagen zur Genetischen Programmierung werden auch die in [PuSL07] eingeführten wahrscheinlichkeitsorientierten (p-) Operatoren berücksichtigt. Die p-Operatoren lehnen sich an den Mutationsoperator der Evolutionsstrategien an und basieren auf definierten Wahrscheinlichkeits- oder Häufigkeitsverteilungen. In der Genetischen Programmierung wird hiermit die zielgerichtete Initialisierung und Mutation ermöglicht. Die vorgenommenen Erweiterungen verallgemeinern den klassischen Ansatz und erhöhen erheblich das Potential zur Berücksichtigung von Domänenwissen im GP-Optimierungsprozess.

Zur Lösungsfindung nutzen Evolutionäre Algorithmen Zufallszahlen, die üblicherweise Werte zwischen 0 und 1 beschreiben. Zur Verwendung der p-Operatoren werden die Wahrscheinlichkeits- und Häufigkeitsverteilungen dementsprechend nicht auf einen Flächeninhalt der Größe 1, sondern auf Werte zwischen 0 und 1 normiert.

### ***Sprachdefinition, Bildungsvorschrift***

Auf Grundlage der Sprachdefinition werden die Genotypen im GP-Optimierungsprozess generiert und variiert. Die Phänotypen (Programme) werden unter Berücksichtigung des festgelegten Regelsystems, der Programmsyntax, evaluiert. Eine derartige Bildungsvorschrift muss zur Repräsentation von komplexen Strukturen die Eigenschaften hoher Flexibilität und Variabilität aufweisen. Die Bildungsvorschrift muss darüber hinaus gewährleisten, dass die Ausprägungen der Genotypen stets korrekte Abbildungen der Aufgabe repräsentieren.

Die Backus-Naur Form (BNF) stellt eine Metasprachdefinition dar, welche die geforderten Eigenschaften erfüllt. Metasprachen sind künstliche Sprachen, die auf einer Syntax beruhen und Regeln zur Definition einer formalen Grammatik beinhalten [Broc03]. Die Genetische Programmierung unter Verwendung von BNF-basierten Bildungsvorschriften (kurz: BNF-Definitionen) wurde erstmals von Geyer-Schulz propagiert [Geye95]. Bei maximaler Flexibilität ermöglichen BNF-Definitionen die präzise Beschreibung der problemspezifischen Anforderungen, die Erzeugung unbegrenzt langer Ausdrücke sowie die Gewährleistung der syntaktischen Richtigkeit der generierten Ausdrücke [Bode04]. Die Genotypen können in Bäumen veranschaulicht werden.

Die Backus-Naur Form unterscheidet nicht-terminierte und terminierte Symbole. Die nicht-terminierten Symbole werden in Klammern  $\langle \rangle$  notiert und sind im Unterschied zu den terminierten weiter aufzulösen. In der Baumrepräsentation beschreiben sie die Baumknoten. Die terminierten Symbole werden mit Hilfe von Anführungszeichen  $' '$  spezifiziert. Sie enthalten Konstanten und die Optimierungsparameter. Diese Symbole bilden die Blätter der Baumdarstellung.

Grundsätzlich wird eine BNF-Regel entsprechend der allgemeinen Darstellung der Gleichung 2.3 angegeben. Nicht-terminierte Symbole werden links vom „:=“-Zeichen vermerkt und durch die Alternativen rechts des Zeichens definiert. Die Alternativen werden mit Hilfe von vertikalen Teilern  $|$  unterschieden.

$$\langle \text{nicht-terminiert} \rangle := \langle \text{der1} \rangle \mid \langle \text{der2} \rangle \mid ' \text{var1} ' \mid ' \text{var2} ' \quad (2.3)$$

Ingenieurprobleme erfordern stets reellwertige Optimierungsparameter. Bei der herkömmlichen BNF werden reellwertige Größen durch die rekursive Verknüpfung terminierter mit nicht-terminierten Symbolen abgebildet. Diese Modellierung hat unübersichtliche und unnötig umfangreiche BNF-Definitionen zur Folge. Zur Repräsentation reeller Werte wurde in [PuSL07] das nicht-terminierte Symbol „Wertebereich“ eingeführt. Ein Wertebereich-Symbol wird durch die drei reellen Werte Minimum, Maximum und Inkrement beschrieben.

Die Abbildung 2.3 zeigt eine beispielhafte BNF-Definition, die im Rahmen einer symbolischen Regression zur Polynom Gewinnung verwendet werden könnte. Individuen werden durch die rekursive Anwendung der definierten nicht-terminierten Symbole erstellt. Die jeweils zugehörige Baumrepräsentation geht bausteinartig aus der BNF-Definition hervor. Die Erzeugung eines Individuums beginnt am nicht-terminierten

Startsymbol  $S$ . Das Symbol `Func` referenziert in einer der beiden Alternativen auf sich selbst. Die rekursive Anwendung kann dementsprechend lange Ausdrücke zur Folge haben. Die Symbole `Fac` und `Pow` repräsentieren Wertebereich-Symbole, gekennzeichnet durch minimalen und maximalen Wert sowie ein Inkrement. Drei mögliche Lösungen, welche der dargestellten BNF-Definition entsprechen, sind dargestellt. Zur Lösung  $y=2.9*x^2$  wird zudem die Baumrepräsentation gezeigt.


#### BNF-Definition

```
<S>      := 'y=' <Func>
<Func>   := <Expr> | <Func> <Opr> <Expr>
<Expr>   := <Fac> '*x^' <Pow>
<Opr>    := '+' | '-'
<Fac>    := [0.0;5.0;0.1]
<Pow>    := [0.0;4.0;1.0]
```

#### Mögliche Individuen

- 1)  $y=2.9*x^2$
- 2)  $y=2.0*x^3-4.1*x^4$
- 3)  $y=1.4*x^1+4.9*x^2+3.9*x^4$

#### Baumrepräsentation des 1. Individuums



**Abbildung 2.3:** Exemplarische BNF-Definition, mögliche Individuen, Baumstruktur

#### Code Aufblähung (Bloat)

Die hohe Flexibilität und Variabilität der Genetischen Programmierung kann ein Aufblähen der genotypischen Repräsentanten zur Folge haben (engl. Code Bloating). Es kann sich ein unkontrolliertes Wachsen der im Optimierungsprozess behandelten Ausdrücke einstellen [BBJP03].

In der beispielhaften Darstellung der Abbildung 2.3 kann das Symbol `Func` aufgrund der Selbstreferenz extrem ausgedehnte Baumstrukturen ergeben. Zudem können Lösungen mehrfach Terme von gleicher Potenz enthalten – die zugehörigen Ausdrücke wären übermäßig lang und könnten kondensiert werden.

Unabhängig von Mechanismen, die Lösungskandidaten gezielt hinsichtlich dieses Phänomens korrigieren, kann mit Hilfe einer adäquaten Sprachdefinition die Art der entstehenden Baumstrukturen sowie deren Hierarchietiefen gesteuert werden. Die Bildungsvorschrift ist auf die erforderlichen Konstrukte zu beschränken und Überflüssiges ist zu vermeiden [Bode04]. Darüber hinaus kann mit Hilfe der zielgerichteten Anwendung der evolutionären Operatoren dem Aufblähen der Genotypen entgegnet werden. Die in [PuSL07] eingeführten wahrscheinlichkeitsorientierten p-Operatoren wirken dem Phänomen des Code Bloatings entgegen.




### Initialisierung

Zur Erzeugung von Initial-Individuen wird die BNF-Definition ausgehend vom Startsymbol  $s$  hierarchisch durchlaufen. Die verschiedenen Alternativen der nicht-terminierten Symbole ermöglichen die Generierung unterschiedlichster Individuen. Die Diversität der Initial-Population wird hierdurch gewährleistet.

Im herkömmlichen GP-Ansatz werden verschiedene Alternativen eines nicht-terminierten Symbols gleichermaßen zur Erstellung der Individuen herangezogen. Mit Hilfe der in [PuSL07] eingeführten p-Initialisierung können in der BNF-Definition einzelne Alternativen von nicht-terminierten Symbolen gegeneinander gewichtet werden. Den Alternativen werden hierzu angestrebte Wahrscheinlichkeiten zugeordnet. Die Zuordnung der Wahrscheinlichkeiten kann durch die Vorgabe von Wahrscheinlichkeits- oder Häufigkeitsverteilungen erfolgen. Zur Verwendung der Normalverteilung würde der Erwartungswert auf die bevorzugte Alternative (terminiertes oder nicht-terminiertes Symbol gleichermaßen) gelegt werden. Nach Vorgabe einer Abweichung  $\sigma$  ergäben sich die angestrebten Auftretenswahrscheinlichkeiten mit Hilfe der Gauß'schen Glockenkurve. Zur Erzeugung eines Initialindividuums werden die Alternativen eines Symbols entsprechend der zugewiesenen Wahrscheinlichkeiten herangezogen.

Die Abbildung 2.4 zeigt für das nicht-terminierte Wertebereich-Symbol  $F_{ac}$  des Beispiels der Abbildung 2.3 eine mögliche p-Initialisierung. Der Ausgangswert einer bereits bekannten Lösung für  $F_{ac}$  (Domänenwissen) betrage 2,0. Unter Zuhilfenahme einer ersten Zufallszahl (bool) wird über eine Verkleinerung oder Vergrößerung des ursprünglichen Werts entschieden. Im vorliegenden Fall wird 2,0 verkleinert. Für eine zweite Zufallszahl (reell,  $\geq 0$  und  $\leq 1$ ) wird der Schnittpunkt mit der Gauß'schen Glockenkurve ermittelt. Die Projektion auf die  $F_{ac}$ -Achse ergibt den neuen Wert. Die Zufallszahl wurde im Beispiel zu 0,6 und  $F_{ac}$  schließlich zu 1,5 bestimmt. Es ist zudem zu erkennen, dass für die Wahrscheinlichkeitsverteilung nicht der Flächeninhalt auf 1 sondern vielmehr die Wahrscheinlichkeiten auf Werte zwischen 0 und 1 normiert wurden.



**Abbildung 2.4:** Wahrscheinlichkeitsorientierte (p-) Operatoren: Beispiel

### **Selektion**

Die Selektion ist unabhängig von der zu Grunde liegenden Datenstruktur. Das Vorgehen zur Auswahl von Individuen zur Bildung der Nachkommen einer neuen Population kann von herkömmlichen Evolutionären Algorithmen übernommen werden.

### **Rekombination**

Der Rekombinationsoperator repräsentiert den wesentlichen evolutionären Operator der GP. Im Vergleich zum herkömmlichen GA weist die GP in der Rekombination eine überragende Performanz auf. GAs nehmen eine Kreuzung an zufällig gewählten Kreuzungspunkten vor. Die Vererbung zusammenhängender genetischer Bausteine (Substrukturen) kann hierbei nicht berücksichtigt werden. Die Teillösungen der Substrukturen gehen unter Umständen verloren.

In der GP werden zur Rekombination Teilbäume der Elter-Baumstrukturen zur Erzeugung eines Nachkommens getauscht. Zum Tausch werden Teilbäume herangezogen, die das gleiche Ursprungssymbol in der BNF-Definition aufweisen. Die Nachkommen sind hiermit zwangsläufig BNF-konform und repräsentieren stets syntaktisch korrekte Ausdrücke. Die Vererbung vollständiger Substrukturen kann zu günstigen Kombinationen der Teillösungen führen, die einen effizienten Optimierungsprozess erheblich unterstützen und eine frühzeitige Annäherung an das Gesamtoptimum erwirken.

Die Wahl der Teilbäume der beiden Eltern erfolgt zufällig und ist somit von der Häufigkeit der nicht-terminierten Symbole in den Elter-Baumstrukturen abhängig. Die Erweiterungen in [PuSL07] sehen zur zielgerichteten Rekombination der Individuen in der Erstellung der BNF-Definition die Angabe von individuellen Rekombinationswahrscheinlichkeiten für die einzelnen nicht-terminierten Symbole vor. Hierdurch können Symbole definiert werden, die in der Ermittlung der Elter-Teilbäume verstärkt als Wurzel-Symbole zur Rekombination herangezogen werden. Dies ermöglicht die Berücksichtigung von Vorwissen über die Problemstellung mit der Anwendung des Rekombinationsoperators. Darüber hinaus können mit Hilfe derartiger Vorgaben die entstehenden Baumstrukturen hinsichtlich ihrer Abbildungslängen günstig beeinflusst werden.

Die Abbildung 2.5 zeigt für das Beispiel der Abbildung 2.3 exemplarisch die Generierung eines Nachkommens aus zwei Eltern. Die Eltern repräsentieren die Lösungen  $y = 2.9 * x^2$  und  $y = 2.0 * x^3 - 4.1 * x^4$ . Als gemeinsames Wurzelsymbol wurde `Expr` gewählt. Zur Generierung des Nachkommens  $N$  wird ein an `Expr` beginnender Teilbaum des Elters  $B$  gegen einen entsprechenden des Elters  $A$  getauscht.

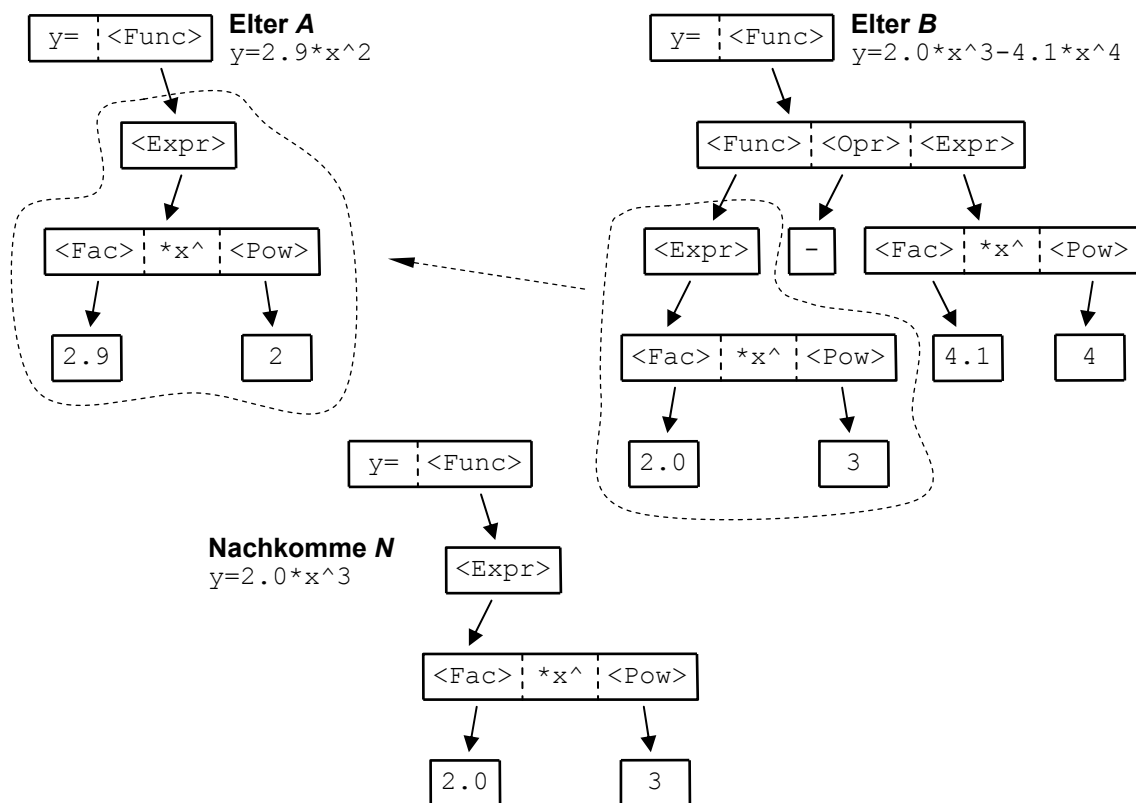


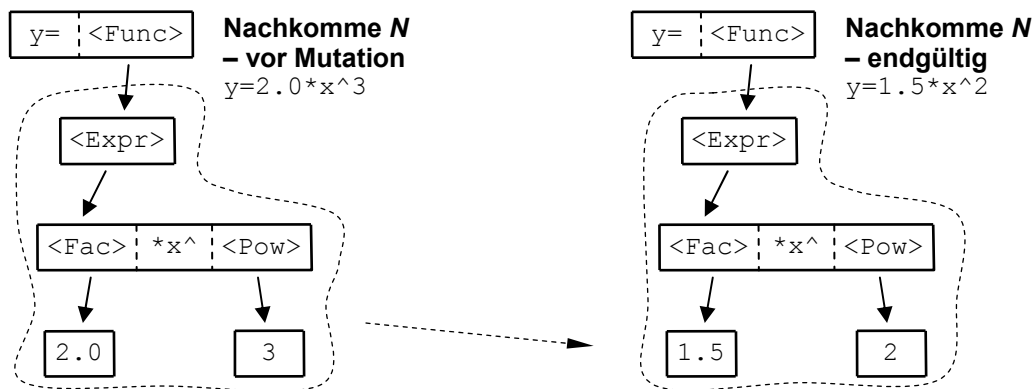
Abbildung 2.5: Genetische Programmierung: Rekombination

### Mutation

Die Mutation ist im konventionellen GP-Ansatz von untergeordneter Bedeutung. Koza, der Begründer der Genetischen Programmierung, verwendete beispielsweise überhaupt keine Mutation [EiSm03].

Zur Mutation eines Individuums wird ein nicht-terminiertes Symbol im Genotyp zufällig gewählt. Der am Symbol anschließende Teilbaum wird gegen einen neu erstellten Baum getauscht. Der neue Teilbaum wird ausgehend vom gewählten nicht-terminierten Symbol basierend auf der BNF-Definition initialisiert. Die Initialisierung des Teilbaums erfolgt in Anlehnung an die Initial-Erzeugung vollständiger Individuen: Statt am Startsymbol  $s$  zu beginnen, wird das vorgegebene Wurzel-Symbol der rekursiven Erstellung der neuen Substruktur zu Grunde gelegt. In Abhängigkeit von der Lage eines gewählten Symbols im zugehörigen Ableitungsbaum können die GP-Individuen im Rahmen der Mutation ggf. in starkem Maße abgeändert werden.

Die Abbildung 2.6 zeigt für den generierten Nachkommen der Abbildung 2.5 eine mögliche Mutation ausgehend vom Symbol  $\text{Expr}$ . Der Nachkomme wird von  $y = 2.0 * x^3$  auf den Ausdruck  $y = 1.5 * x^2$  abgewandelt.



**Abbildung 2.6:** Genetische Programmierung: Mutation

Zur Beeinflussung der zunächst zufälligen Wahl des Wurzel-Symbols berücksichtigen die Erweiterungen in [PuSL07] die Möglichkeit der Vorgabe von Mutationswahrscheinlichkeiten für die einzelnen Symbole der BNF-Definition. Hierdurch können die Symbole gekennzeichnet werden, welche in besonderem Maße als Wurzel-Symbole in der Mutation herangezogen werden sollen. Ähnlich dem Vorgehen der Rekombination kann hiermit Domänenwissen in den Optimierungsprozess einfließen und die Hierarchietiefen der entstehenden Baumstrukturen können gesteuert werden.

Neben den bereits beschriebenen Verallgemeinerungen der GP in [PuSL07] liegt jedoch die bedeutendste Neuerung in der Einführung des Operators der p-Mutation. Mit der p-Mutation erhält die GP einen evolutionären Operator, welcher bezüglich der Performanz dem Rekombinationsoperator in keiner Weise nachsteht. Statt des Tauschs eines Teilbaums gegen einen vollständig neu erstellten Baum wird zur p-Mutation die ursprüngliche Teillösung in die Erstellung des neuen Teilbaums miteinbezogen und geringfügig modifiziert. Zur Erstellung des neuen Teilbaums werden ausgehend vom gewählten Wurzel-Symbol die jeweiligen Alternativen der nicht-terminierten Symbole in der BNF-Definition mit angepassten Wahrscheinlichkeits- oder Häufigkeitsverteilungen belegt. Als Wahrscheinlichkeitsverteilung kann beispielsweise die Normalverteilung verwendet werden: Die für ein Symbol ursprünglich verwendete Alternative wird als Erwartungswert definiert. Mit Hilfe einer vorgegebenen Abweichung wird nun für ein nicht-terminiertes Symbol eine Alternative gewählt, die vornehmlich aus dem Nachbarbereich der ursprünglichen Alternative stammt. Erwartungswert und Abweichung beziehen sich hierbei allgemein auf die Anzahl der vorhandenen Alternativen. Die rein zufällige Auswahl der Alternativen des herkömmlichen Mutations-Operators wird im Operator der p-Mutation durch die zielgerichtete Bestimmung der Alternativen ersetzt. Das grundlegende Vorgehen stimmt mit der p-Initialisierung überein und wurde anhand

eines Wertebereich-Symbols und der Abbildung 2.4 dargelegt. Ein weiteres ausführlich dargestelltes Beispiel kann dem Kapitel 3.5.3 und den Erläuterungen zur Abbildung 3.15 entnommen werden.

Der Rekombinationsoperator gewährleistet wesentlich die Diversität der Populationen und unterstützt die Suche der globalen Extrema (Exploration). Die p-Mutation erlaubt die zielgerichtete Verbesserung von Lösungskandidaten. In Anlehnung an die Mutation der Evolutionsstrategien können kleine Veränderungen eingestellt und Nachbarschaftsbereiche von bereits bekannten guten Lösungen untersucht werden (Exploitation).

Die Kombination der beiden Operatoren im Rahmen eines adaptiv gesteuerten evolutionären Algorithmus verspricht eine effiziente Lösungssuche und erhebliche Steigerungen der Performanz des gesamten Optimierungsprozesses. Die dargestellten p-Operatoren verallgemeinern die Genetische Programmierung deutlich und ergänzen diese um extrem leistungsstarke Hilfsmittel zur detaillierten Berücksichtigung von Domänenwissen im Optimierungsprozess [PuSL07].

## 2.3 Künstliche Neuronale Netze

### 2.3.1 Allgemeines


Künstliche Neuronale Netze (NN) sind mathematische Modelle biologischer Nervenzellnetzwerke. Die Informationsverarbeitung des natürlichen Vorbilds wird abstrahiert und dessen Struktur nachgebildet. Mit ihrer Hilfe können komplexe nichtlineare Zusammenhänge abgebildet und Probleme gelöst werden, deren explizite Modellierung nicht oder nur mit Schwierigkeiten möglich ist. Das Haupteinsatzgebiet ist die Mustererkennung. Der Inferenzprozess ist nicht einsehbar (Black-Box-System), was bei Mustererkennungsproblemen im Allgemeinen auch nicht gefordert wird [Adam03].

Die wesentliche Eigenschaft der Neuronalen Netze liegt in ihrer Lernfähigkeit. Ihr Verhalten ergibt sich als Folge eines Einlernens (auch: Training) unter Verwendung eines Lernverfahrens. Mit der Lernfähigkeit geht der Aspekt der Generalisierung einher: Trainierte Netze sind in der Lage, Probleme zu lösen, die nicht explizit im Lernprozess berücksichtigt wurden. Die Generalisierung ermöglicht eine enorme Fehlertoleranz gegenüber gestörten und unvollständigen Eingabedaten [NaKK96].

Eine Nervenzelle des menschlichen Gehirns besteht aus einem Zellkörper (Soma), verzweigten Auswüchsen (Dendriten) und einer langen Nervenfasern (Axon) mit Verbin-

dungsstellen (Synapsen), wie schematisch in der Abbildung 2.7 gezeigt. Über die Dendriten werden Signale anderer Zellen aufgenommen und das Neuron erregt (aktiviert). Erreicht die Erregung einen gewissen Schwellenwert, erfolgt eine Reizweiterleitung über das Axon, den Signalausgang der Zelle. Die am Axon angeschlossenen Synapsen übergeben den Reiz an die Dendriten nachgeschalteter Zellen und können signalverstärkend (excitatorisch) oder -hemmend (inhibitorisch) wirken. Die menschliche Großhirnrinde besteht aus etwa  $10^{10}$  bis  $10^{12}$  Nervenzellen, die durchschnittlich  $10^4$  Verbindungen aufweisen und somit hochgradig vernetzt vorliegen [NaKK96, MaHS03].

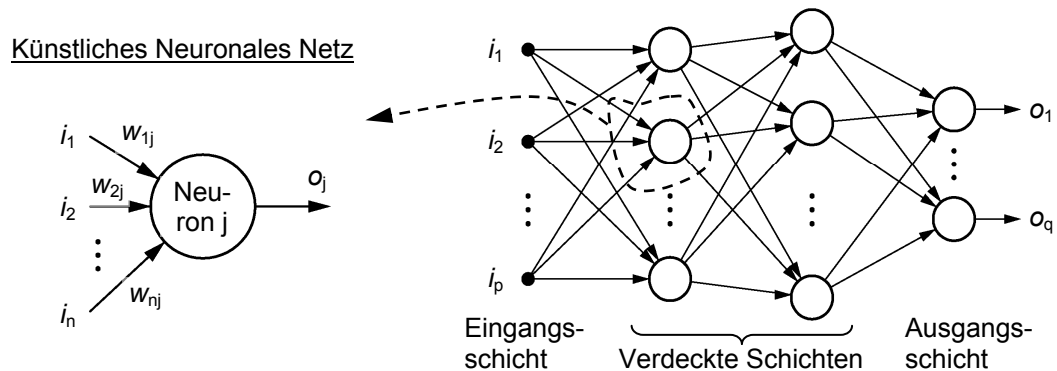
Aus systemtheoretischer Sicht stellt ein einzelnes Neuron eine relativ simple Verarbeitungseinheit dar, welche einen oder mehrere Eingänge aufnimmt und einen Ausgang aufweist. Dem biologischen Vorbild nachempfunden erfolgt die Datenverarbeitung im Neuron dreistufig im Rahmen der Neuronenfunktionen: Propagierungs-, Aktivierungs- und Ausgabefunktion. Die Propagierungsfunktion führt gewichtete Eingaben zur Netzeingabe zusammen. Die Aktivierungsfunktion verarbeitet die Netzeingabe unter Berücksichtigung eines Schwellenwerts. Die Ausgabefunktion bestimmt den Ausgabewert.



**Abbildung 2.7:** Vergleich: Natürliches und künstliches Neuron

Als konnektionistisches Modell wird eine hohe Anzahl künstlicher Neuronen in einem dichten Netzwerk, dem künstlichen Neuronalen Netz, zusammengefasst. Die Neuronen arbeiten hierbei lokal und kommunizieren über die Verbindungen. In Abhängigkeit von der Ausbildung der Verbindungen sowie von Parametern der Verarbeitungseinheiten kann ein komplexes globales Verhalten realisiert werden. Die eigentlichen Berechnungen erfolgen jedoch in den Neuronen, den Elementarbausteinen der Netzwerke. Die Abbildung 2.8 zeigt ein einzelnes Neuron sowie eine beispielhafte Vernetzung. Im Neuron wurde die dreistufige Datenverarbeitung nach Abbildung 2.7 zusammengefasst. In

der Netz-Darstellung als Graph repräsentieren die Neuronen die Knoten und deren Verbindungen die Kanten.



**Abbildung 2.8:** Exemplarische Darstellung eines künstlichen Neuronalen Netzes

Gemäß der Abbildung 2.8 bestehen die hier betrachteten künstlichen Neuronalen Netze aus insgesamt  $p$  Eingängen  $i$  und  $q$  Ausgängen  $o$ . Im Aufbau werden die Ein- und Ausgangsschicht von den verdeckten Schichten unterschieden. Bei einer Anzahl von  $r$  Schichten liegen  $r - 2$  verdeckte Schichten vor. Die Elemente der Eingangsschicht führen keine Informationsverarbeitung aus und stellen daher keine Neuronen im eigentlichen Sinne dar. Sämtliche Einheiten einschließlich der Eingangselemente werden von der Ein- zur Ausgangsschicht durchnummeriert. Das Neuron  $j$  weist  $n$  Eingänge und den Ausgang  $o_j$  auf. An der Verbindung von Element  $k$  zur Einheit  $j$  liegt das Gewicht  $w_{kj}$  an. Interne Ein- und Ausgänge der einzelnen Verarbeitungseinheiten sind von den externen des gesamten Netzes zu unterscheiden.

McCulloch und Pitts entwickelten Anfang der 1940er Jahre ein erstes mathematisches Modell eines Neurons [McPi43]. 1949 postulierte Hebb eine erste Lernregel [Hebb49]. Hierauf aufbauend stellte 1958 Rosenblatt das erste lernfähige künstliche Neuronale Netz, das Perceptron, vor [Rose58]. Minsky und Papert zeigten Ende der 1960er Jahre, dass das damals bevorzugt untersuchte Perceptron Probleme eines speziellen Aufgabenbereichs nicht lösen konnte [MiPa69]. Die gezeigte Grenze führte zu einem abnehmenden Interesse an der Erforschung von künstlichen Neuronalen Netzen und einer massiven Einschränkung der Forschungsgelder. Sowohl die Vertiefung der Theorie der künstlichen Neuronalen Netze als auch die Entdeckung von neuen mächtigen Lernverfahren, insbesondere des Backpropagation-Verfahrens, führte ab Mitte der 1980er Jahre zu einem erneuten Aufleben des Forschungsgebiets.

Nachfolgend werden die NN-Komponenten erläutert, welche für verschiedene künstliche Neuronale Netze gleichermaßen gelten.

### Propagierungsfunktion


Die Propagierungsfunktion  $f_{\text{pro}}$  nimmt für das Neuron  $j$  (vgl. Abbildung 2.8) die internen Eingaben  $i$  entgegen und ermittelt unter Berücksichtigung der Gewichte  $w$  der Verbindungen die Netzeingabe  $\text{net}_j$  (Gleichung 2.4). Üblicherweise wird  $\text{net}_j$  als gewichtete Summe gemäß Gleichung 2.5 bestimmt. Um hierbei eine Unterscheidung zwischen exzitatorischen und inhibitorischen Einflüssen treffen zu können, werden häufig Gewichte eines zu 0 symmetrischen Wertebereichs (bspw.  $[-1; +1]$ ) eingesetzt.

$$\text{net}_j = f_{\text{pro}}(w_{1j}, \dots, w_{nj}, i_1, \dots, i_n) \quad (2.4)$$

$$\text{net}_j = \sum_{k=1}^n (w_{kj} \cdot i_k) \rightarrow \text{Gewichtete Summe (häufige Umsetzung)} \quad (2.5)$$

### Aktivierungsfunktion

Die Aktivierungsfunktion  $f_{\text{act}}$  bestimmt für das Neuron  $j$  aus der Netzeingabe  $\text{net}_j$ , dem Schwellenwert  $\Theta_j$  und dem vorherigen Aktivierungszustand  $a_j^{\text{old}}$  dessen Aktivität  $a_j$  (Gleichung 2.6). Dem biologischen Vorbild entsprechend beschreibt der Schwellenwert den Grenzwert, ab welchem ein Neuron feuert. Übliche Aktivierungsfunktionen, die  $a_j^{\text{old}}$  nicht berücksichtigen, sind der Abbildung 2.9 zu entnehmen. Die Fermi-Funktion zählt zur Gruppe der sigmoiden (s-förmigen) Funktionen. Diese Funktionen sind nach unten und oben beschränkt, stetig differenzierbar und streng monoton steigend.



**Abbildung 2.9:** Verschiedene Aktivierungsfunktionen

Die Fermi-Funktion ist aufgrund ihrer Leistungsfähigkeit und der guten mathematischen Handhabbarkeit die am häufigsten eingesetzte Aktivierungsfunktion [Adam03]. Für den



Parameter  $c = 1,0$  ohne Berücksichtigung von  $a_j^{\text{old}}$  wird ihre Definition mit der Gleichung 2.7 gegeben.

$$a_j = f_{\text{act}}(\text{net}_j, \Theta_j, a_j^{\text{old}}) \quad (2.6)$$

$$a_j = \left(1 + e^{-(\text{net}_j - \Theta_j)}\right)^{-1} \rightarrow \text{Fermi-Funktion (häufige Umsetzung)} \quad (2.7)$$

### **Ausgabefunktion**

Die Ausgabefunktion  $f_{\text{out}}$  berechnet auf Basis der Aktivierung  $a_j$  den Ausgabewert  $o_j$  (Gleichung 2.8). Sehr häufig wird die Identität gemäß Gleichung 2.9 verwendet.

$$o_j = f_{\text{out}}(a_j) \quad (2.8)$$

$$o_j = a_j \rightarrow \text{Identität (häufige Umsetzung)} \quad (2.9)$$

### **Topologien**

Künstliche Neuronen können auf beliebige Weise miteinander vernetzt werden. Häufig werden sie in Schichten angeordnet, wie bereits anhand der Abbildung 2.8 erläutert. Abhängig von der Anzahl der Schichten, welche Verarbeitungseinheiten enthalten, wird von einem  $(r - 1)$ -schichtigen Neuronalen Netz gesprochen.

Typische Netzstrukturen stellen die vorwärtsbetriebenen (feedforward) und rekurrenten Netze dar. Bei feedforward Netzen bestehen Verbindungen in Richtung der Ausgangsschicht ausschließlich zwischen den Elementen der direkt aufeinander folgenden Schichten. Netze, deren einzelne Elemente mit jeder Einheit der nachfolgenden Schicht verbunden sind, werden als vollverknüpft bezeichnet. Rekurrente Netze erweitern die feedforward Struktur und gestatten Verbindungen einzelner Neuronen zu sich selbst (direkte Rückkopplung oder auch Selbstrekurrenz), Verbindungen in Richtung der Eingabeschicht (indirekte Rückkopplung) sowie Verbindungen zwischen Neuronen einer Schicht (laterale Verbindungen). In rekurrenten Netzen können die Neuronen aufgrund der vorhandenen Rückkopplungen sich selbst beeinflussen.

### **Lernverfahren**

Im Lernprozess (auch: Training) wird ein Neuronales Netz derart angepasst, dass es zu einer vorgegebenen Eingabe eine gewünschte Ausgabe produziert. Insbesondere die Verbindungsgewichte  $w$  sowie die Schwellenwerte  $\Theta$  der Neuronen werden ermittelt. Darüber hinaus kann der Lernalgorithmus das Entwickeln zusätzlicher und Entfernen

bestehender Verbindungen oder Neuronen vorsehen. Das Hinzufügen bzw. Löschen von Verbindungen kann gleichermaßen mit Gewichten realisiert werden, welche auch den Wert 0 annehmen können. Das Abändern der Neuronen ist biologisch nur eingeschränkt motiviert, verändert die Topologie und erfordert daher komplexe Optimierungsverfahren. Die Neuronenfunktionen (Propagierungs-, Aktivierungs- und Ausgabefunktion) können ebenfalls für einzelne Neuronen adaptiert werden – in der Praxis werden diese üblicherweise einheitlich für die Neuronen eines Netzes definiert [Adam03].

Grundsätzlich werden die Paradigmen des Überwachten und des Unüberwachten Lernens unterschieden [NaKK96]. Beim Überwachten Lernen liegen zusammengehörige Ein- und Ausgabepaare vor, die zur Netzkonfiguration den Ist-Soll-Vergleich ermöglichen. Derartige Netze werden zur Regression und zur Approximation eingesetzt. Beim Unüberwachten Lernen liegen ausschließlich Eingabemuster vor, die durch Klassifizierung erlernt werden. Entsprechend trainierte Netze können zur Feststellung von gemeinsamen Charakteristika der Eingabedaten (vgl. Self-Organizing Maps, [Vesa02]) oder zur Datenreduktion (bspw. Autoencoder-Netzwerke, [HiSa06]) verwendet werden.


### 2.3.2 Singlelayer-Perceptrons

Singlelayer-Perceptrons (SLP) sind einschichtige vorwärtsbetriebene Neuronale Netze ohne innere Schichten. Die Eingabedaten werden somit direkt an die Neuronen der Ausgabeschicht weitergeleitet.

Das Perceptron (engl. Perception = Wahrnehmung) wurde 1958 von Rosenblatt vorgestellt [Rose58] und weist ein einziges Ausgabeneuron auf. Zur Propagierung wird die gewichtete Summe, zur Aktivierung die Heavyside-Funktion und die Identität als Ausgabefunktion verwendet. Dem Perceptron liegt die Idee zu Grunde, auf einer imaginären Retina eine Mustererkennung vorzunehmen. Entsprechend der gewählten Aktivierungsfunktion, die ausschließlich Werte von 0 oder 1 produziert, entscheidet das Perceptron, ob ein Muster (bspw. ein Buchstabe) auf der Retina erscheint.

Als Verallgemeinerung des Perceptrons wurden lineare Modelle entwickelt. Die Modelle beschränken die Ausgabeschicht nicht auf ein einzelnes Element und berechnen die Aktivität des Neurons  $j$  über den linearen Zusammenhang  $a_j = \text{net}_j + \Theta_j$ . Die Lernregel entspricht der Delta-Regel (auch: Widrow-Hoff-Regel, [WiHo60]) oder der Hebbischen Regel [Hebb49]. Das Anwendungsgebiet stellt, wie beim Perceptron auch, die Mustererkennung dar. Aufgrund der höheren Netzkapazität repräsentieren sie die bedeutend fehlertoleranteren Assoziativspeicher [NaKK96].

Es zeigte sich, dass SLP und ihre Lernregeln nicht in der Lage sind, nicht linear separierbare Probleme zu lösen [MiPa69]. Die Abbildung 2.10 zeigt im Vergleich die OR- und XOR-Funktion. Die Ausgabewerte der OR-Funktion lassen sich im zweidimensionalen Raum durch eine Gerade in zwei Mengen aufteilen. Die Teilung der Ergebniswerte der XOR-Funktion ist mit einer Geraden nicht möglich, die Funktion gilt als nicht linear separierbar. Zur Lösung derartiger Aufgaben mit künstlichen Neuronalen Netzen müssen innere Verarbeitungseinheiten eingeführt werden. Seinerzeit war kein Lernverfahren bekannt, um die Verbindungsgewichte der inneren Neuronen zu trainieren.



**Abbildung 2.10:** Lineare Separabilität: a) OR-Funktion und b) XOR-Funktion

Die Leistungsfähigkeit der SLP wird durch das Kriterium der linearen Separabilität stark eingeschränkt. Sie sind jedoch aufgrund ihrer Einfachheit für verschiedene Aufgaben prädestiniert [NaKK96].

### 2.3.3 Multilayer-Perceptrons

Multilayer-Perceptrons (MLP) stellen mehrschichtige feedforward Systeme dar, die keinerlei Beschränkungen hinsichtlich der Neuronenanzahl in der Ausgabeschicht vorsehen (vgl. auch Abbildung 2.8). Die Aktivierungsfunktionen müssen nichtlinear sein, da mehrschichtige lineare Systeme analytisch in gleichwertige einschichtige Netzwerke überführt werden können [NaKK96]. Aufgrund der Berücksichtigung von inneren Schichten können auch nicht linear separierbare Probleme gelöst werden.

Mehrschichtige Netzwerke sind universelle Approximatoren: Unter Annahmen bezüglich des zu Grunde liegenden Eingaberaums und der Art der Aktivierungsfunktionen können Aussagen über die Fähigkeit der Neuronalen Netze getroffen werden, eine gegebene stetige Funktion beliebig genau zu approximieren. Die Netzwerke erfordern hierzu ausschließlich eine einzelne innere Schicht. Zell erläutert in [Zell03] ausführlich unterschiedliche Herangehensweisen der Beweisführung und die jeweils getroffenen Annahmen. Die theoretischen Resultate verdeutlichen das enorme MLP-Potential zur Abbildung von komplexen nichtlinearen Zusammenhängen. Die Ergebnisse sind jedoch wenig hilfreich in der Konstruktion konkreter Netzwerke, da keine Angaben hinsicht-

lich der erforderlichen Anzahl an inneren Neuronen, der Art der Aktivierungsfunktionen, des Lernverfahrens und der Parameter des Lernverfahrens getroffen werden [NaKK96, Zell03]. Insbesondere im Rahmen von praktischen Anwendungen können Netze mit mehreren verdeckten Schichten geeignet sein, weil diese zur gegebenen Problemstellung „schneller trainieren oder generalisieren“ [Zell03].

Die wichtigste MLP-Eigenschaft ist deren überragende Generalisierungsfähigkeit [NaKK96]: Im Lernprozess gewinnt ein MLP eine allgemeingültige Abbildungsvorschrift, die es ihm ermöglicht, Eingabedaten, die nicht im NN-Training berücksichtigt wurden, auf die zugehörige Ausgabe abzubilden. Die Wahl der notwendigen Anzahl verdeckter Neuronen ist hierbei von hoher Bedeutung. Bei zu geringer Anzahl vermag das MLP die Lernaufgabe nicht zu lösen. Bei zu hoher Anzahl kann sich der Effekt der Übergeneralisierung einstellen: Das Netz lernt erfolgreich, erzeugt jedoch für unbekannte Eingaben unerwartete Ausgaben. Gleichmaßen kann die einseitige Wahl der Trainingsmuster eine – einseitige – MLP-Überanpassung zur Folge haben.

Das MLP-Training erfolgt üblicherweise mit Hilfe des Backpropagation-Algorithmus [RuHW86]. Der Algorithmus basiert auf der Minimierung einer Fehlerfunktion, welche zu Trainingsdatensätzen die Ausgabewerte eines MLP mit den Zielwerten vergleicht. Zur Anpassung der Verbindungsgewichte und Schwellenwerte werden ermittelte Fehler rückwärts, in Richtung der Eingabeschicht propagiert. Da das Lernverfahren die Delta-Regel [WiHo60] für mehrschichtige Systeme erweitert, wird es auch als verallgemeinerte Delta-Regel bezeichnet. Der Lernalgorithmus erfordert die Verwendung von kontinuierlichen und differenzierbaren Aktivierungsfunktionen.

Backpropagation ist ein Gradientenabstiegsverfahren und kann in lokalen Minima der Fehlerfunktion stecken bleiben. In steilen „Schluchten“ der Fehlerfunktion neigt das Verfahren zum Oszillieren, in flachen Abschnitten zum „Kriechen“. Verschiedene Modifikationen verbessern das Verfahren und sollten im Training von mehrschichtigen Netzen berücksichtigt werden. Ausführliche Beschreibungen der Erweiterungen können [Adam03] und [Zell03] entnommen werden.

Aufgrund der inhärenten enormen Generalisierungsfähigkeit und der vorhandenen leistungsstarken Lernverfahren versprechen Multilayer-Perceptrons, geeignete Mittel zur Mustererkennung in einer realen Anwendung zu sein. Die Fehlertoleranz gegenüber störbehafteten Eingabedaten sowie Aspekte der Übergeneralisierung sind im Rahmen einer Evaluierung von unterschiedlichen Netztopologien zu überprüfen.

## Kapitel 3

# Identifikation von Verkehrslasten – IIM

### 3.1 Allgemeines

Die Identifikation von Verkehrslasten auf der Basis von gemessenen statischen Tragwerksreaktionen erfordert die Lösung einer inversen Problemstellung. Geschlossene analytische Lösungen bestehen ausschließlich für lineare mechanische Systeme. Für nichtlineare Systeme des Brückenbaus und Brücken beliebiger Spannweiten existieren bisher keine zufrieden stellenden Ansätze. Mit dem IIM (Identification-in-Motion) Algorithmus wird in diesem Kapitel ein Verfahren der Identifikation von Verkehrslasten für Brückenüberbauten vorgestellt, welches gleichermaßen auf lineare und nichtlineare mechanische Systeme angewendet werden kann. Die Übertragbarkeit auf Brücken größerer Spannweiten wird durch die Berücksichtigung von verschiedenen Tragwerksreaktionen in der Messdatenanalyse gewährleistet. Der Ansatz erfüllt die Anforderung, dass zur Auswertung realer Messungen eine minimale Anzahl an Messsensoren eingesetzt wird. Die Messungen können mit Hilfe von konventioneller Messtechnik durchgeführt werden. Der IIM-Algorithmus ist geeignet, Verkehrslasten an Brückenkonstruktionen der Beton-, Stahl- und Stahlverbundbauweise zu identifizieren.

In IIM werden verschiedene Methoden des Soft Computing zur Messdatenanalyse in sinnvoller Weise zusammengeführt. Angewandte Soft Computing Techniken sind stets im Umfeld der zu Grunde liegenden Problemstellung zu betrachten. Zur Identifikation von Verkehrslasten auf der Basis von gemessenen Dehnungen werden daher nachfolgend die geeigneten Tragwerksreaktionen anhand eines Berechnungsbeispiels analysiert. In den darauf folgenden Abschnitten wird auf die entwickelten evolutionären Optimierungsverfahren einschließlich der hybriden Einbindung von künstlichen Neuronalen Netzen und die Zusammenführung der Methoden im IIM-Algorithmus eingegangen.

## 3.2 Tragwerksreaktionen der Lastidentifikation

Die Lastidentifikation auf der Basis von stochastischen Suchverfahren ist rechenintensiv. Der Rechenaufwand wird maßgeblich durch die Anzahl der Sensorsignale bestimmt, welche zur Analyse der erfassten Tragwerksreaktionen herangezogen werden. Der Entwurf eines effizienten Verfahrens der Lastidentifikation erfordert daher die Beschränkung auf die Tragwerksreaktionen, welche in besonderem Maße auf die einwirkenden Lasten schließen lassen. Die Verwendung der minimal erforderlichen Anzahl an Messelementen erfüllt zudem praxisrelevante Anforderungen: Eine unnötig hohe Anzahl an Sensoren verringert die Wirtschaftlichkeit und erhöht den Installations- und Wartungsaufwand der Messeinrichtung.


Das Verständnis der Tragwerksreaktionen von Brückenüberbauten infolge von Verkehrslasten bildet die Grundlage zur Feststellung der minimal erforderlichen Anzahl an Messelementen bei zweckmäßiger Wahl der Messstellen am Überbau. Nachfolgend werden anhand eines Berechnungsbeispiels die Tragwerksreaktionen erläutert, welche zur Identifikation von Verkehrslasten geeignet sind. Die Untersuchungen finden an einer zweistegigen Plattenbalkenbrücke statt. Der Fahrbahnquerschnitt sei der einer einbahnigen Kreisstraße mit einem Fahrstreifen je Richtung (siehe Abbildung 3.1). Zur Darstellung von qualitativen Dehnungsentwicklungen infolge einer vorgegebenen Verkehrsbelastung wurden linear elastische Berechnungen durchgeführt.

Es wird eine Unterscheidung nach globalen und lokalen Reaktionen vorgenommen [LuBa00]. Globale Reaktionen werden durch die Messung an Haupttragelementen eines Überbaus erfasst. Ein entsprechend installierter Sensor liefert ein signifikantes Signal während der gesamten Überfahrt eines Fahrzeugs. Die Reaktionen sind von zeitlich ausgedehnter Dauer. Lokale Reaktionen werden in direkter Nähe zu den einwirkenden Radlasten aufgezeichnet. Im Vergleich zu den globalen Reaktionen sind diese Reaktionen von zeitlich kurzer Dauer. Grundsätzlich enthalten Tragwerksreaktionen beide Komponenten. Je nach Messstelle wird ein Sensorsignal jedoch durch globale oder lokale Reaktionen dominiert.

Für das Bauwerk der Abbildung 3.1 (siehe auch Anhang A) wurden die Überfahrten des 5-achsigen Sattelzugs und des 3-achsigen Lastkraftwagens im Fahrstreifen 1 simuliert. Für beide Fahrzeuge wurde eine Geschwindigkeit  $v$  von 72 km/h angesetzt. Der Sattelzug weist ein Gesamtgewicht von 40,6 t und der Lastkraftwagen ein Gewicht von 32,6 t auf. Die Berechnungen wurden in einem Finite Elemente Programmsystem durchgeführt. Dehnungen, die im Rechenmodell für eine betrachtete Tragwerksstelle zur An-



wurden am Steg, welcher dem Fahrzeug zugewandt, die Dehnungen  $\Delta\epsilon_{c,2}$  am Steg, der dem Fahrzeug abgewandt war, ermittelt. Sowohl  $\Delta\epsilon_{c,1}$  als auch  $\Delta\epsilon_{c,2}$  beschreiben Querschnittsdehnungen in Überbau-Längsrichtung. Die Ergebnisse sind auf das Tragverhalten des Überbaus als Durchlaufträger über zwei Felder zurückzuführen. Die gezeigten Verläufe werden maßgeblich durch die Fahrzeugattribute Gesamtgewicht und Geschwindigkeit bestimmt. Die einzelnen Achslasten des Fahrzeugs stellen sich in den Dehnungsverläufen nicht dar. Für die gesamte Dauer der Fahrzeugüberfahrt sind Werte  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$  festzustellen. Es liegen globale Tragwerksreaktionen vor. Die Abtastung eines derart zeitlich ausgedehnten Signals, welches die Folge von übergeordneten Fahrzeugattributen darstellt, könnte mit einer Frequenz  $f_s \geq 10$  Hz erfolgen. Bei  $f_s = 10$  Hz würde für ein Fahrzeug, welches mit 20 m/s (72 km/h) das Bauwerk überfährt, alle 2 m ein diskreter Messwert erhalten werden.




**Abbildung 3.2:** Globale Reaktionen: Dehnungen  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$  im a) Feld- und b) Stützquerschnitt zur Überfahrt des Sattelzugs

Die Querverteilung der Fahrzeuglasten schlägt sich in den Dehnungsverläufen der Abbildung 3.2 deutlich nieder: Nach 0,6 s befindet sich der Sattelzug direkt am untersuchten Feldquerschnitt. Bei dieser Laststellung beteiligt sich der Steg, welcher der Last zugewandt ist, zu 62 % am Lastabtrag. Steht der Sattelzug im nachfolgenden Feld, werden die Stege des betrachteten Feldquerschnitts gleichermaßen beansprucht. Die Erläuterungen gelten sinngemäß für den Stützquerschnitt. Die Kenntnis der Querverteilung der Lasten ermöglicht die Zuordnung des Fahrstreifens, auf welchem ein Fahrzeug fuhr. Unter Berücksichtigung der Querverteilung der Lasten können für das betrachtete Beispiel die Querschnittsdehnungen infolge einer Fahrzeugüberfahrt auch durch die Auswertung der Einflusslinien für das jeweilige Biegemoment bestimmt werden.

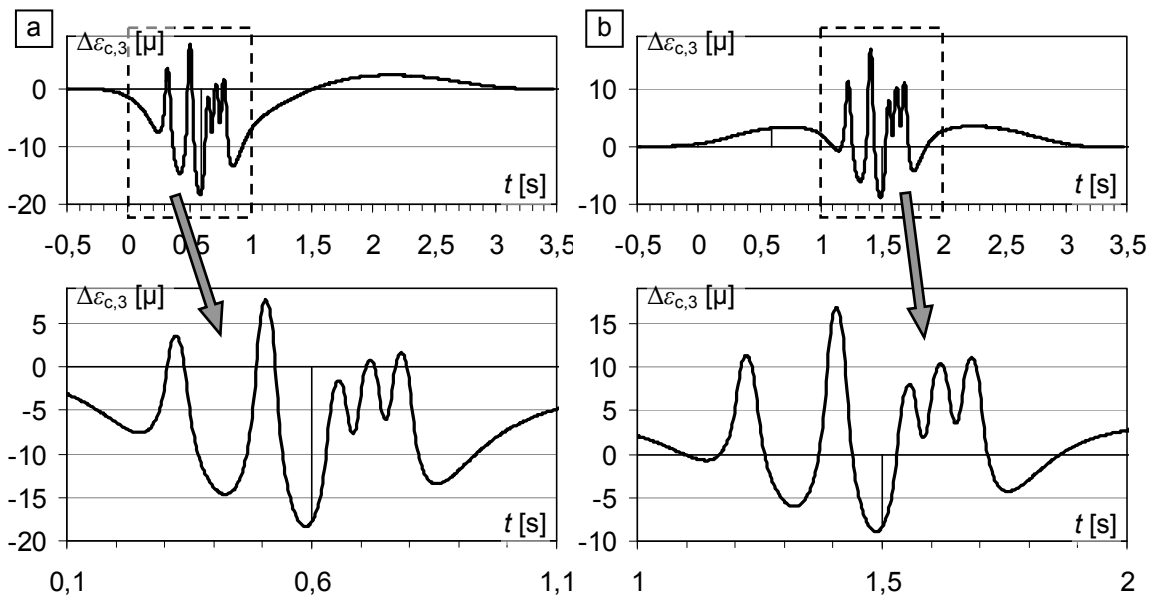
Die Dehnungsentwicklungen  $\Delta\epsilon_{c,1}$  für den Feld- und den Stützquerschnitt zur Überfahrt von Sattelzug und Lastkraftwagen sind der Abbildung 3.3 zu entnehmen. Die Trag-



werksreaktionen infolge der Belastung durch beide Fahrzeuge ergeben sich aus der Kombination der Reaktionen für die einzelnen Fahrzeuge.



**Abbildung 3.3:** Globale Reaktionen: Dehnungen  $\Delta\epsilon_{c,1}$  im a) Feld- und b) Stützquerschnitt zur Überfahrt von Sattelzug und Lastkraftwagen

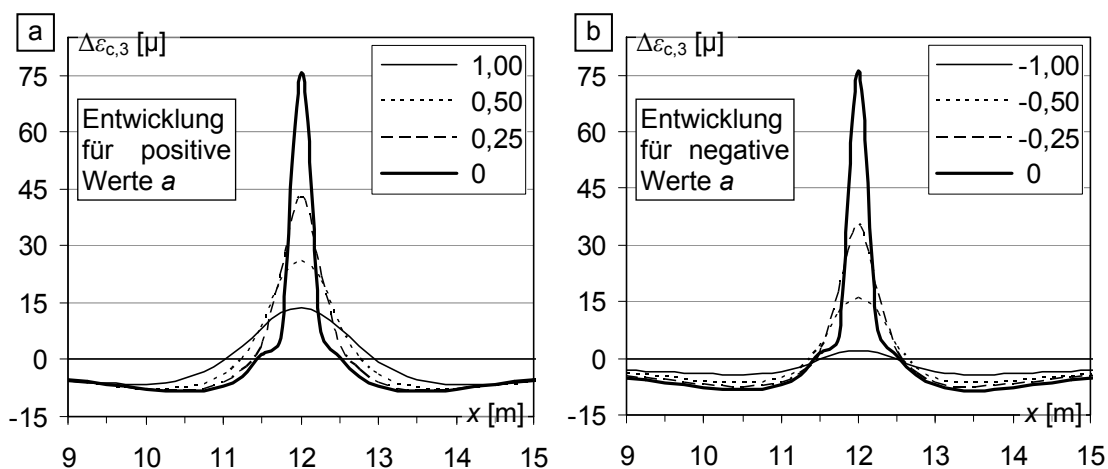


**Abbildung 3.4:** Lokale Reaktionen: Dehnungen  $\Delta\epsilon_{c,3}$  im a) Feld- und b) Stützquerschnitt zur Überfahrt des Sattelzugs

Für den Feld- und den Stützquerschnitt werden in der Abbildung 3.4 die Längsdehnungen  $\Delta\epsilon_{c,3}$  zur Überfahrt des Sattelzugs dargestellt. Die gezeigten Tragwerksreaktionen umfassen sowohl globale als auch lokale Anteile. Die globalen Anteile sind, ähnlich zu  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$ , auf ein Tragverhalten des gesamten Überbaus zurückzuführen. Im Vergleich zu  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$  fallen die globalen Anteile der Dehnungen  $\Delta\epsilon_{c,3}$  dem Betrag nach signifikant geringer aus. Lokale Reaktionen sind für den Zeitpunkt der Überfahrt des jeweils betrachteten Querschnitts festzustellen. Obwohl die Fahrbahnplatte Lasten

einachsrig in Überbau-Querrichtung abträgt, stellt sich unter konzentrierten Einzellasten eine lokal begrenzte Längstragwirkung ein. Insbesondere in den vergrößerten Ansichten sind deutlich Tragwerksreaktionen infolge der einzelnen Radlasten zu erkennen. Die Reaktionen sind von zeitlich kurzer Dauer und können dem verursachenden Fahrzeug direkt zugeordnet werden. Zur Erfassung der lokalen Tragwerksreaktionen ist eine Abtastfrequenz  $f_s \geq 100$  Hz erforderlich. Für ein Fahrzeug mit der Geschwindigkeit 20 m/s würde alle 20 cm der Überfahrtsstrecke ein Messwert aufgezeichnet werden.


Zur Erläuterung der lokalen Reaktionen wurden an der Stelle  $x/y = 12,00/6,65$  m (vgl. Abbildung 3.1) der Fahrbahnplatte die Einflussflächen der Schnittgrößen  $m_x$ ,  $n_x$ ,  $m_y$  und  $n_y$  (siehe Abbildungen A.3 bis A.6) für eine Wanderlast von 100 kN ausgewertet und in Dehnungen  $\Delta\epsilon_{c,3}$  überführt. Für verschiedene Koordinaten  $a$  wurden Werte  $\Delta\epsilon_{c,3}$  unter Berücksichtigung der Querkontraktion entsprechend der mechanischen Beziehung  $\epsilon_x = 1/E \cdot (\sigma_x - \nu \cdot \sigma_y)$  mit  $\nu = 0,2$  ermittelt. Die erhaltenen Ergebnisse werden in der Abbildung 3.5 gezeigt. Die lokalen Anteile der dargestellten Reaktionen  $\Delta\epsilon_{c,3}$  werden vornehmlich durch die Schnittgrößen  $m_x$  und  $m_y$  bestimmt. Die Normalkräfte  $n_y$  sind vernachlässigbar klein. Die Größe  $n_x$  stellt die Folge einer globalen Überbau-Tragwirkung dar. Die Einflussflächen für  $m_x$  und  $m_y$  konzentrieren sich stark um die Stelle  $x/y = 12,00/6,65$  m und fallen vergleichsweise schnell auf geringe Werte ab. Dementsprechend ist aus der Abbildung 3.5 zu entnehmen, dass sich die lokalen Tragwerksreaktionen in Längsrichtung ausschließlich über einen sehr kurzen Bereich ausbilden. Aus der Darstellung der Dehnungsentwicklungen für positive und negative Werte  $a$  geht hervor, dass zur Untersuchung von Dehnungen  $\Delta\epsilon_{c,3}$  beide Radreihen des Fahrzeugs und deren Abstand  $a$  zu einer Messstelle zu berücksichtigen sind.



**Abbildung 3.5:** Lokale Reaktionen: Dehnungen  $\Delta\epsilon_{c,3}$  für eine Wanderlast der Größe 100 kN für a) positive Werte  $a$  und b) negative Werte  $a$

Für überholende Fahrzeuge oder Fahrzeuge im Gegenverkehr (Fahrstreifen 2) ergeben sich Dehnungen  $\Delta\epsilon_{c,4}$ , die aufgrund der Querschnittssymmetrie Ähnlichkeit zu den bereits gezeigten Dehnungen  $\Delta\epsilon_{c,3}$  aufweisen. Lokale Reaktionen der Dehnungen  $\Delta\epsilon_{c,4}$  stellen die Folge von Fahrzeugen im Fahrstreifen 2 dar. Der Einfluss von Fahrzeugen im Fahrstreifen 1 auf die lokalen Anteile ist vergleichsweise gering (vgl. hierzu Abbildung 3.5). Diese Feststellungen gelten sinngemäß für die Stelle  $\Delta\epsilon_{c,3}$ .

Die Dehnungsentwicklungen in Fahrbahnplatten-Querrichtung  $\Delta\epsilon_{c,5}$  während der Überfahrt des 5-achsigen Sattelzugs werden für den Feld- und den Stützquerschnitt in der Abbildung 3.6 angegeben. Da die Fahrbahnplatte einachsige Lasten abträgt, stellen sich Werte lediglich bei Anwesenheit des Fahrzeugs in unmittelbarer Nähe zum jeweils betrachteten Querschnitt ein. Das Erscheinungsbild der Dehnungsverläufe  $\Delta\epsilon_{c,5}$  wird durch das Fahrzeuggesamtgewicht sowie die einzelnen Achslasten bestimmt. Im Vergleich zu den Dehnungen  $\Delta\epsilon_{c,3}$  sind einzelne Achsen jedoch nicht zweifelsfrei zu erkennen. Im Unterschied zu  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$  ist das Signal von zeitlich kurzer Dauer und muss mit einer vergleichsweise hohen Frequenz von mindestens 100 Hz abgetastet werden.



**Abbildung 3.6:** Dehnungen  $\Delta\epsilon_{c,5}$  im a) Feld- und b) Stützquerschnitt zur Überfahrt des Sattelzugs

Die Ergebnisse der Untersuchungen lassen folgende Schlussfolgerungen zu:

Die zweckmäßige Wahl von Messstellen am Überbau ermöglicht den Erhalt von Sensorsignalen, welche eindeutig durch globale oder lokale Reaktionen dominiert werden. Insbesondere die Tragwerksreaktionen der Überbau-Längsrichtung zeigten deutlich globale ( $\Delta\epsilon_{c,1}$ ,  $\Delta\epsilon_{c,2}$ ) oder lokale Reaktionen ( $\Delta\epsilon_{c,3}$ ,  $\Delta\epsilon_{c,4}$ ) bei jeweils signifikanten Amplituden der entsprechenden Dehnungen. Die Dehnungen der Fahrbahnplattenmitte in Überbau-Querrichtung ( $\Delta\epsilon_{c,5}$ ) ließen weder globale noch lokale Reaktionen klar erkennen. Tabelle 3.1 stellt die Erkenntnisse zusammen.

**Tabelle 3.1:** Geeignete Messstellen

	Lage im Querschnitt, vgl. Abbildung 3.1				
	$\Delta\epsilon_{c,1}$	$\Delta\epsilon_{c,2}$	$\Delta\epsilon_{c,3}$	$\Delta\epsilon_{c,4}$	$\Delta\epsilon_{c,5}$
Globale Reaktionen	+	+	–	–	–
Lokale Reaktionen	–	–	+	+	–

Legende: '+' hohe Bedeutung der Reaktion, '–' geringe Bedeutung der Reaktion

Die Ergebnisse verdeutlichen, dass globale und lokale Tragwerksreaktionen jeweils sehr klar definierte Eigenschaften aufweisen. Globale Reaktionen werden vornehmlich durch übergeordnete Fahrzeugattribute, wie das Gesamtgewicht und die Geschwindigkeit, beschrieben. Die Reaktionen sind von zeitlich ausgedehnter Dauer und eine Aufzeichnung kann bei vergleichsweise geringer Abtastfrequenz erfolgen. Lokale Reaktionen stellen die Folge der Achslasten und -abstände der Fahrzeuge dar. Diese Reaktionen sind von kurzer Zeitdauer und erfordern eine hohe Abtastfrequenz. Eine Übersicht der Merkmale kann der Tabelle 3.2 entnommen werden.

**Tabelle 3.2:** Merkmale globaler und lokaler Tragwerksreaktionen

	Globale Reaktionen	Lokale Reaktionen
Dominierende Fahrzeugattribute	<u>Fahrzeugeigenschaften:</u> <ul style="list-style-type: none"> <li>• Gesamtgewichte</li> <li>• Geschwindigkeiten</li> </ul>	<u>Achseigenschaften:</u> <ul style="list-style-type: none"> <li>• Achslasten</li> <li>• Achsabstände</li> </ul>
Abtastfrequenz / zu verarbeitendes Datenvolumen	gering ( $\geq 10$ Hz)	hoch ( $\geq 100$ Hz)


Die sinnvolle Zusammenführung unterschiedlicher Tragwerksreaktionen in einem adäquaten Messdatenanalyse-Verfahren verspricht, einzelne Fahrzeuge, die den instrumentierten Überbau einer Brücke überfahren, und deren zugehörige Attribute zu identifizieren. Der Entwurf eines effizienten Verfahrens muss hierbei insbesondere unterschiedlichen Abtastfrequenzen der globalen und lokalen Messsignale und den hiermit einhergehenden Anforderungen an die Messdatenauswertung gerecht werden.

### 3.3 Vorgehensweise der Lastidentifikation

Der IIM-Algorithmus dient zur Analyse von statischen Tragwerksreaktionen, welche an entsprechend instrumentierten Brückenüberbauten erfasst werden. Im Vorgehen wird unterschieden nach globalen und lokalen Tragwerksreaktionen. Einzelne Fahrzeuge und deren zugehörige Attribute werden aus Messdaten identifiziert, welche die Folge eines

einzelnen oder mehrerer Fahrzeuge auf dem Bauwerk darstellen. Die Messungen werden mit der minimal erforderlichen Anzahl an Sensoren durchgeführt. Bei der Messung kommen konventionelle Dehnmessstreifen und induktive Wegaufnehmer zum Einsatz. Die Anordnung der Sensoren erfolgt in einem begrenzten Bereich – gegebenenfalls in einem Querschnitt – des Überbaus. Die Sensoren können daher direkt mit Hilfe von Kabeln an die Messanlage angeschlossen werden. Hierdurch wird eine Dauermessung ermöglicht. Messinstallationen auf der Fahrbahnoberfläche, welche traditionelle Ansätze zur Ermittlung der Fahrzeuggeschwindigkeit und Auftretenszeitpunkte der Fahrzeugachsen voraussetzen, sind nicht erforderlich.

Die Identifikation von Verkehrslasten wird im Algorithmus durch die Adaption der Lastkomponente von numerischen Rechenmodellen auf Grund des Vergleichs von deren Vorhersage mit Beobachtungen der Realität durchgeführt. Die Kenntnis der Systemkomponente der Rechenmodelle wird vorausgesetzt (vgl. auch Gleichung 1.1). Zur Lastidentifikation werden die Ergebnisse von kontinuierlichen Messungen betrachtet. Im Unterschied zur Analyse von Messwerten mehrerer Sensoren, die zu definierten Zeitpunkten aufgenommen werden, unterstützt ein Ansatz auf der Basis von kontinuierlichen Messgrößen die Verwendung einer geringen Sensoranzahl und ermöglicht die Aufnahme des gesamten Verkehrsflusses. Das prinzipielle Vorgehen der Lastidentifikation wird schematisch anhand des zweifeldrigen Brückenbauwerks der Abbildung 3.7 gezeigt: Unbekannte Parameter, wie das Fahrzeuggesamtgewicht und die -geschwindigkeit, Achslasten und -abstände werden im Rahmen von Optimierungsprozessen solange variiert, bis numerisch ermittelte Dehnungen  $\Delta\epsilon_c$  die am Bauwerk gemessenen Dehnungen  $\Delta\epsilon_m$  mit gewissen definierten Toleranzen wiedergeben.

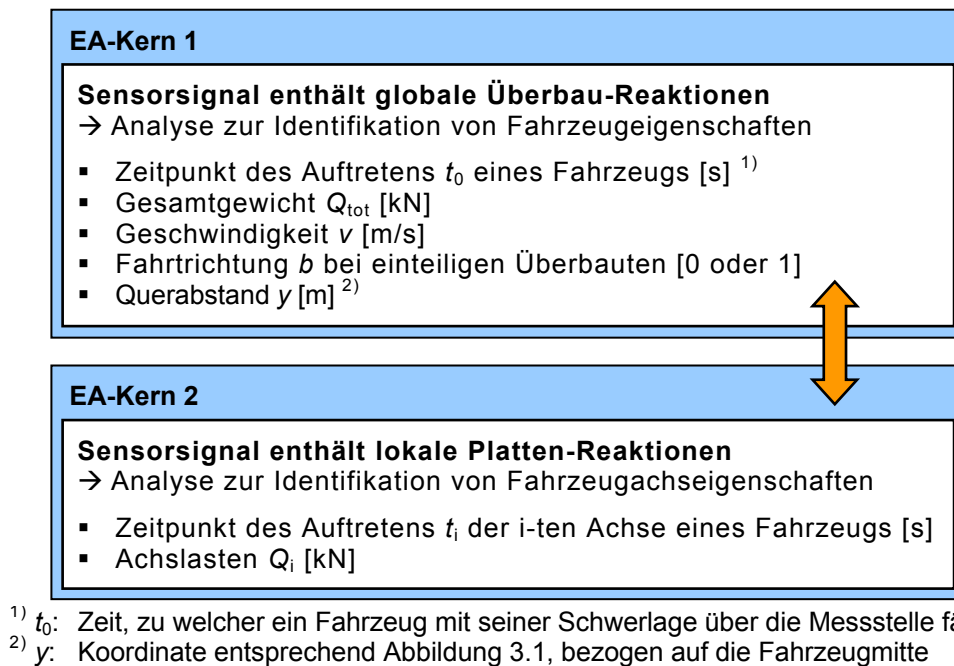


**Abbildung 3.7:** Prinzipielles Vorgehen der Lastidentifikation

Da Messungen kaum in allen Freiheitsgraden der Rechenmodelle vorgenommen werden können, wird die jeweils vorliegende Belastungssituation auf der Basis unvollständiger und begrenzter Informationen ermittelt. In der Regel existiert keine eindeutige Lösung. Die Probleme gelten als schlecht-gestellt („ill-posed“). Für die Verwendung von Optimierungsverfahren zur Lösungsfindung bedeutet dies, dass mehrere lokale Extrema bestehen und traditionelle lokale Suchalgorithmen möglicherweise zu Lösungen führen, die nicht die tatsächliche Belastungssituation repräsentieren. Zur Lösung der Problemstellung wird im IIM-Algorithmus aus dem Gebiet der Evolutionären Algorithmen (EA) die Genetische Programmierung (GP) eingesetzt. Die Verwendung von Genetischer Programmierung erfüllt die Anforderung, dass dynamische, flexible Repräsentationsformen für komplexe Optimierungsaufgaben der Modelladaption besser geeignet sind als die fixe, einschränkende Repräsentation von Lösungskandidaten in binär- oder reell-codierten Vektoren fest vorgegebener Länge [ChGh01, LiRa05, YaWS05]. Als Bildungsvorschrift, auf deren Basis Lösungskandidaten im evolutionären Optimierungsprozess generiert und variiert werden, wird die Backus-Naur Form verwendet.

Die Identifikation von Verkehrslasten wird im Rahmen zweier gekapselter evolutionärer Optimierungskerne durchgeführt. Ein Optimierungskern dient zur Auswertung von erfassten globalen Tragwerksreaktionen, wohingegen der zweite Kern lokale Reaktionen analysiert (siehe Abbildung 3.8). Die Analyse der beiden Tragwerksreaktionen führt je Reaktionsart auf die Feststellung definierter Fahrzeugattribute: Globale Überbaureaktionen dienen zur Bestimmung von übergeordneten Fahrzeugkennwerten, lokale Plattenreaktionen werden zur Ermittlung von Achseigenschaften der Fahrzeuge herangezogen. In der direkten Unterscheidung nach globalen und lokalen Tragwerksreaktionen tragen die beiden Reaktionsarten jeweils bestmöglich zur Feststellung einzelner Attribute der Fahrzeuge bei (vgl. auch Tabelle 3.2). Die Berücksichtigung von zwei getrennten Optimierungskernen zur Ermittlung der Fahrzeugattribute minimiert den Suchraum der Problemstellung und steigert die Gesamteffizienz des Algorithmus.

Die Abbildung 3.8 zeigt die Parameter, welche im Rahmen der beiden Optimierungsverfahren zur Analyse der globalen (EA-Kern 1) und der lokalen Reaktionen (EA-Kern 2) behandelt werden. Attribute, welche aus den evolutionär optimierten Größen abgeleitet werden, sind in der Abbildung nicht enthalten. Beispielsweise werden die Auftretenszeitpunkte und Geschwindigkeiten der Fahrzeuge in den Optimierungsprozessen berücksichtigt. Der Abstand zweier Fahrzeuge wird hingegen aus deren Auftretenszeitpunkten und Geschwindigkeiten ermittelt. Der Fahrzeugabstand stellt keine Optimierungsgröße dar und ist daher nicht dargestellt.



**Abbildung 3.8:** Evolutionäre Optimierungskerne und zugehörige Fahrzeugattribute

Im jeweiligen Optimierungsprozess werden Lastkomponenten der Rechenmodelle hinsichtlich ihrer Repräsentation der wirklichen Messwerte bewertet. Als das wesentliche Optimierungsziel wird die Minimierung der Fehlerquadratsumme (FQS) aus gemessenen  $\Delta \varepsilon_m$  und numerisch berechneten Dehnungen  $\Delta \varepsilon_c$  definiert. Die Werte  $\Delta \varepsilon_c$  beschreiben zur Fahrzeugüberfahrt die Dehnungsentwicklungen, die sich im Rechenmodell am Ort der eingesetzten Sensoren ergeben. Aufgrund der Berücksichtigung der FQS als maßgebendes Kriterium der Zielfunktionen ist der Ansatz wenig sensitiv bezüglich Signalrauschen. Die entwickelten Methoden werden nachfolgend anhand des vorherigen Berechnungsbeispiels (vgl. Kapitel 3.2) erläutert, sind jedoch von allgemeiner Natur und können zur Analyse von realen Messungen verwendet werden (vgl. Kapitel 5, 6).

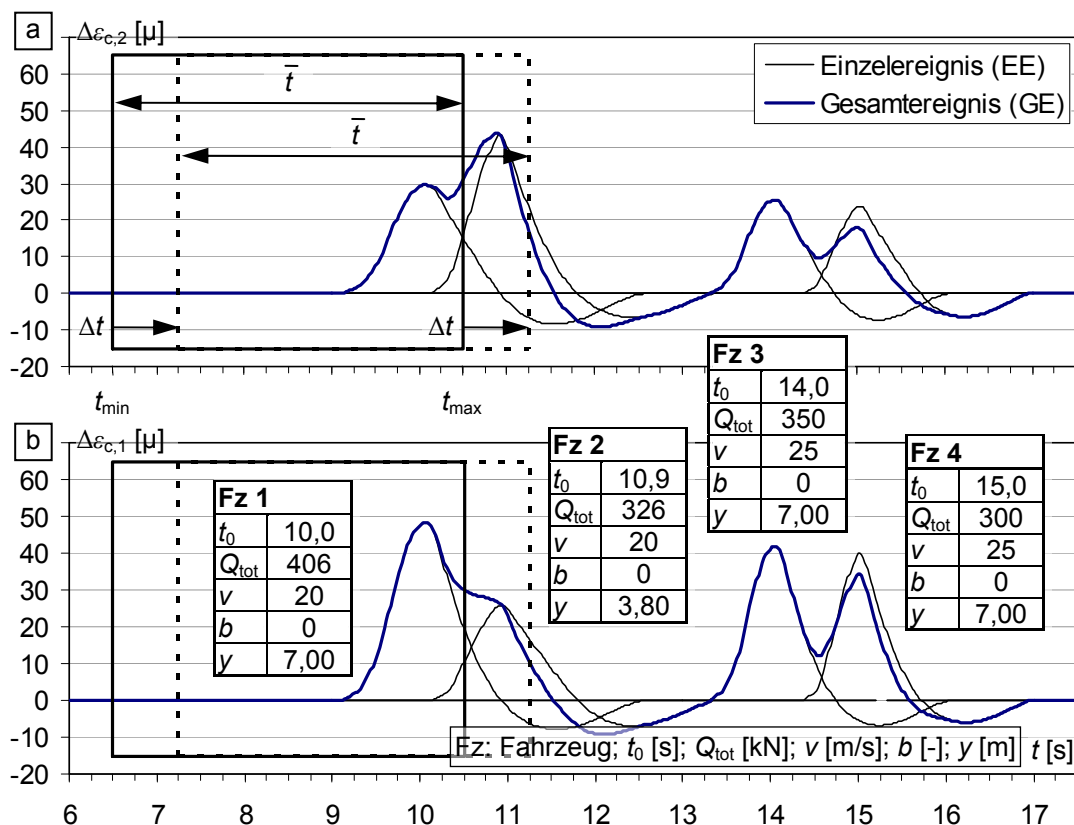
## 3.4 Analyse globaler Tragwerksreaktionen

### 3.4.1 Voraussetzungen

Globale Reaktionen von Brückentragwerken sind von zeitlich ausgedehnter Dauer. Die Reaktionen eines Überbaus zu einer Belastungssituation können die Folge eines oder mehrerer Fahrzeuge auf dem Bauwerk darstellen. Gemessene Werte können ein Fahrzeug oder die Kombination mehrerer Fahrzeuge repräsentieren. Fahrzeuge, die in zeitlich kurzem Abstand ein Brückenbauwerk überfahren, können globale Tragwerksreak-

tionen bewirken, die keine ausgeprägte Amplitudenausbildung des einzelnen Fahrzeugs erkennen lassen. Insbesondere Fahrzeuge auf verschiedenen Fahrstreifen oder mit stark unterschiedlichen Gewichten stellen sich in der globalen Messaufzeichnung nicht zwangsläufig mit deutlich zu erkennenden Amplituden dar.

Zur Verdeutlichung zeigt die Abbildung 3.9 exemplarisch für das zuvor betrachtete numerische Beispiel (vgl. Kapitel 3.2) berechnete Dehnungen  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$ . Die dargestellten Verläufe geben die Dehnungsentwicklung im Feldquerschnitt infolge der Überfahrten von vier aufeinander folgenden Fahrzeugen wieder. Die Abbildung enthält sowohl die Dehnungen infolge der einzelnen Fahrzeuge (Fz) als auch deren Kombination. Die wesentlichen Fahrzeugattribute sind der Abbildung zu entnehmen. Im Fahrstreifen 1 fuhren ein 5-achsiger Sattelzug (Fz 1, vgl. Abbildung 3.1) und zwei fiktive Fahrzeuge (Fz 3: 5 Achsen und Fz 4: 3 Achsen). Im Fahrstreifen 2 befand sich zur Simulation ein 3-achsiger Lastkraftwagen (Fz 2, vgl. Abbildung 3.1) im Überholverkehr.



**Abbildung 3.9:** Analyse globaler Reaktionen: Zeitintervalle  $\bar{t}$ , Zeitschritte  $\Delta t$ , Gesamtereignis (GE) und Einzelereignisse (EE)

Zur Erfassung des gesamten Verkehrsflusses berücksichtigt der Ansatz die Analyse von kontinuierlich erfassten Tragwerksreaktionen. Die Messdatenanalyse wird hierzu in



Zeitschritten  $\Delta t$  unter Auswertung von zugehörigen Zeitintervallen der Länge  $\bar{t}$  durchgeführt. Ein aktuell betrachtetes Zeitintervall beginnt bei dem Zeitwert  $t_{\min}$  und endet bei  $t_{\max} = t_{\min} + \bar{t}$ . Es gilt  $\Delta t \ll \bar{t}$ ; aufeinander folgende Zeitintervalle überschneiden sich somit.

Die Messdaten eines Zeitintervalls werden im Rahmen eines auf Genetischer Programmierung (GP) basierenden Optimierungsverfahrens analysiert. Die zu identifizierende Belastungssituation wird objektorientiert abgebildet: Ein Gesamtereignis (GE) repräsentiert die Kombination einzelner Fahrzeuge und setzt sich hierzu aus Einzelereignissen (EE) zusammen, welche die wirklichen Fahrzeuge beschreiben. Im EA wird eine Population codierter GE-Lösungskandidaten den evolutionären Operatoren unterzogen und zur Lösung der Problemstellung verbessert. Nach Durchlauf des EA wird die jeweils beste Lösung, der Gewinner  $GE_{\text{best}}$ , im statischen Gesamtereignis  $GE_{\text{stat}}$  vorgehalten. Das  $GE_{\text{stat}}$  existiert über alle Zeitschritte und die Gesamtdauer der Messdatenanalyse.

Im Rahmen der Analyse der globalen Reaktionen werden einzelne Fahrzeuge identifiziert und deren Attribute Auftretenszeitpunkt  $t_0$ , Gesamtgewicht  $Q_{\text{tot}}$ , Geschwindigkeit  $v$ , Fahrtrichtung  $b$  und Querabstand  $y$  (vgl. auch Tabelle 3.2 und Abbildung 3.8) ermittelt. Im Verfahren werden mehrere Sensorsignale berücksichtigt.

### 3.4.2 Initialisierung

Da Zeitschritte  $\Delta t \ll \bar{t}$  ausgeführt werden, ändert sich mit der Durchführung eines Zeitschritts die Umgebung vom vorherigen zum aktuellen Zeitintervall nur geringfügig. Die Ergebnisse der GP-Analyse des vorherigen Zeitintervalls stellen infolgedessen eine erste Lösung zur Untersuchung des aktuellen Zeitintervalls dar. Die Population der Individuen zur Auswertung des aktuellen Zeitintervalls wird zweckmäßigerweise basierend auf den bereits erhaltenen Ergebnissen initialisiert. Eine derartige Einbeziehung von Vorwissen in die Generierung der Population zur Analyse des aktuellen Zeitintervalls führt zu einer dynamischen Anpassung des EA an die Optimierungsaufgabe. In dieser Weise kann eine deutlich erhöhte Optimierungseffizienz erzielt werden.

Im gewählten GP-basierten Ansatz erfolgt die Initial-Erzeugung der Individuen auf Basis der Backus-Naur Form (BNF)-Definition. Zur zielgerichteten Generierung der Initial-Population muss das vorhandene Vorwissen in die Erstellung der BNF-Definition einfließen. Die BNF-Definition wird daher auf Basis des  $GE_{\text{stat}}$  und der zugeordneten Einzelereignisse angelegt. Zugleich müssen mögliche Folgefahrzeuge, also zusätzliche Einzelereignisse, berücksichtigt werden.

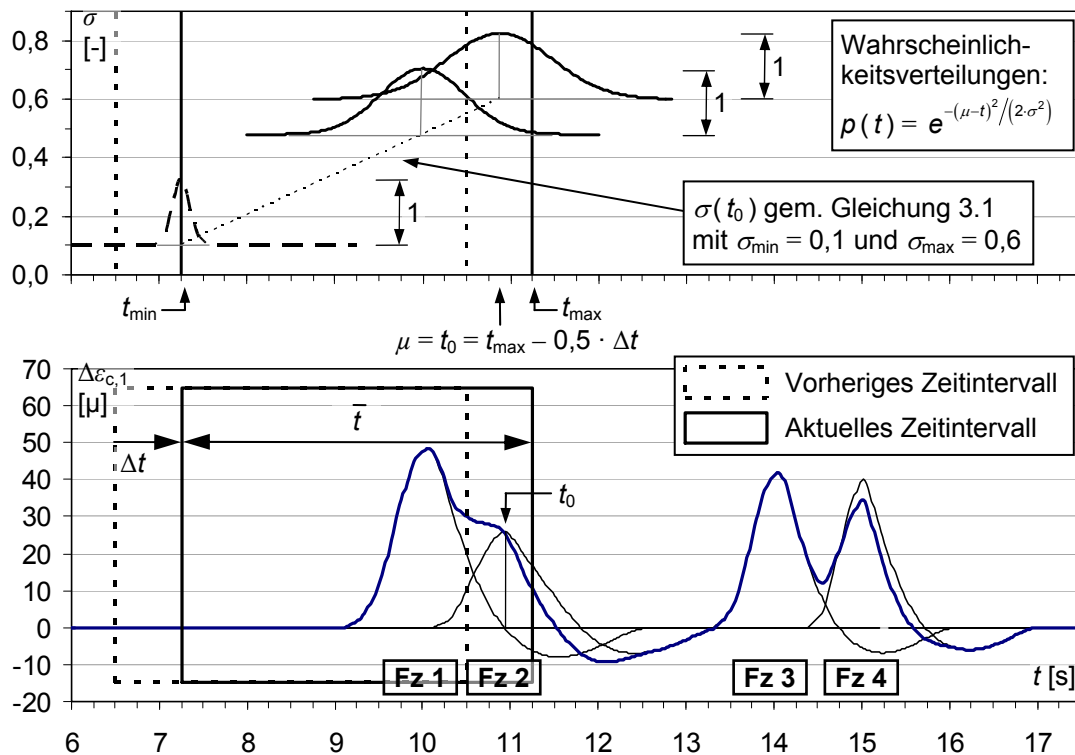
Zur Erstellung der BNF-Definition werden die Einzelereignisse des  $GE_{\text{stat}}$  entsprechend ihrer Ergebnisse für die einzelnen Fahrzeugattribute aufgenommen. Folgefahrzeuge werden durch die Feststellung maßgeblicher Dehnungswerte im Bereich des Zeitwerts  $t_{\text{max}}$  des aktuellen Zeitintervalls detektiert. Der Auftretenszeitpunkt eines Folgefahrzeugs wird zunächst mit  $t_0 = t_{\text{max}} - 0,5 \cdot \Delta t$  angenommen. Die sonstigen Fahrzeugattribute werden zufällig gewählt. Hiernach kann das Fahrzeug einschließlich seiner Attribute in der Erstellung der BNF-Definition berücksichtigt werden.

Die numerischen Werte der Fahrzeugattribute werden in der BNF-Definition mit Hilfe des nicht-terminierten Wertebereich-Symbols [PuSL07] abgebildet. Für die Attribute wird hierdurch ein zu untersuchender Optimierungsbereich definiert. Die zielgerichtete Initialisierung erfolgt mit Hilfe der Vorgabe einer angepassten Normalverteilung als Wahrscheinlichkeitsverteilung für die einzelnen Attribute. Der Erwartungswert  $\mu$  wird auf den bereits bekannten Ergebniswert des Fahrzeugattributs gelegt. Die Abweichungen  $\sigma$  werden für die Attribute eines Fahrzeugs in Abhängigkeit vom Auftretenszeitpunkt  $t_0$  gemäß Gleichung 3.1 bestimmt. Die Größen  $\sigma_{\text{min}}$  und  $\sigma_{\text{max}}$  beschreiben hierbei Werte, die für die einzelnen Fahrzeugattribute vorzugeben sind.

$$\sigma(t_0) = \frac{(\sigma_{\text{max}} - \sigma_{\text{min}}) \cdot (t_0 - t_{\text{min}})}{t_{\text{max}} - t_{\text{min}} - 0,5 \cdot \Delta t} + \sigma_{\text{min}} \quad (3.1)$$

Mit dem Fortschreiten der Messdatenanalyse über Zeitschritte wird die Gauß'sche Glockenkurve zur Initialisierung der Attribute stetig verengt. Die Wahrscheinlichkeit, dass mit der Initial-Erzeugung der Individuen die Ergebnisse der Analyse des vorherigen Zeitintervalls maßgeblich abgeändert werden, wird über die Zeitschritte verringert.

Zur Erläuterung werden in der Abbildung 3.10 die Dehnungen  $\Delta\epsilon_{c,1}$ , welche sich infolge der vier Fahrzeuge der Abbildung 3.9 ergaben, gezeigt. Das aktuelle Zeitintervall beginnt bei  $t_{\text{min}} = 7,25$  s und endet bei  $t_{\text{max}} = 11,25$  s. Die Länge  $\bar{t}$  des Zeitintervalls beträgt somit 4,0 s, der Zeitschritt  $\Delta t$  sei 0,75 s. Mit der Durchführung des Zeitschritts stellt Fz 2 ein Folgefahrzeug dar, Fz 1 wäre in Form eines Einzelereignisses bereits im  $GE_{\text{stat}}$  enthalten. Stellvertretend für die sonstigen Fahrzeugattribute werden im oberen Teil der Abbildung die Wahrscheinlichkeitsverteilungen zur Initialisierung der Auftretenszeitpunkte gezeigt. Für  $\sigma_{\text{min}} = 0,1$  und  $\sigma_{\text{max}} = 0,6$  ergibt sich gemäß Gleichung 3.1 für Fz 2 bei einem angenommenen Auftretenszeitpunkt  $t_0 = t_{\text{max}} - 0,5 \cdot \Delta t = 10,875$  s eine Breite  $\sigma = 0,6$  und für das bereits festgestellte Fz 1 mit  $t_0 = 10,0$  s ein verminderter Wert  $\sigma = 0,48$ . Die stetige Verengung der Glockenkurven ist deutlich zu erkennen.



**Abbildung 3.10:** Erstellung der BNF-Definition, Berücksichtigung von Vorwissen

Die Initialisierung der numerischen Werte der Fahrzeugattribute auf der Grundlage von vordefinierten Wahrscheinlichkeitsverteilungen ist ein extrem leistungsstarkes Hilfsmittel der GP. Neben der Berücksichtigung der Ergebnisse der Analyse des vorherigen Zeitintervalls kann mit Hilfe von adaptierten Wahrscheinlichkeitsverteilungen auch Domänenwissen bezüglich der Auftretenshäufigkeiten der Gesamtgewichte, der Geschwindigkeiten, der Fahrtrichtung und/oder des Querabstands modelliert werden. Hierzu können Häufigkeitsverteilungen, welche für die einzelnen Fahrzeugattribute im Rahmen früherer oder begleitender Untersuchungen gewonnen wurden, herangezogen werden. Insbesondere mit Hilfe von Silhouettenerhebungen kann vor Ort das Fahrverhalten hinsichtlich der Fahrtrichtung und des Querabstands abgeschätzt werden. Zur Identifikation von einzelnen Fahrzeugen auf mehreren Fahrstreifen können mit dieser Kenntnis verschiedene Auftretenswahrscheinlichkeiten für Folgefahrzeuge in den jeweiligen Fahrstreifen in der BNF-Definition abgebildet werden.

Für das betrachtete Zeitintervall der Abbildung 3.10 enthält die Abbildung 3.11 beispielhaft eine mögliche BNF-Definition. Die Bildungsvorschrift umfasst zwei Einzelereignisse ( $0_{EE}$  und  $1_{EE}$ ), welchen je eines der beiden Fahrzeuge zugeordnet ist. Für jedes Einzelereignis werden die Fahrzeugattribute ( $T$ ,  $Q$ ,  $V$ ,  $B$  und  $Y$ ) vollständig definiert. Dies ermöglicht die Zuweisung angestrebter Wahrscheinlichkeiten zur Wahl von

Alternativen während der Initial-Erzeugung von Individuen. Einzelereignisse, die im Optimierungsprozess das Schlüsselwort 'entfaellt' aufweisen, werden zur Fitnesswertermittlung nicht berücksichtigt. Nach Durchlauf des EA werden derartige Einzelereignisse nicht in das statische Gesamtereignis  $GE_{stat}$  übertragen und somit verworfen.


```

<S>          := <0_EE> <1_EE>
<0_EE>       := <0_T0> <0_Q> <0_V> <0_B> <0_Y> | 'entfaellt'
<0_T>        := [9.5;10.5;0.1]
<0_Q>        := [355;463;1]
<0_V>        := [15.0;30.0;1.0/3.6]
<0_B>        := '0' | '1'
<0_Y>        := [3.25;4.25;0.05] | [6.50;7.50;0.05]
<1_EE>       := <1_T0> <1_Q> <1_V> <1_B> <1_Y> | 'entfaellt'
<1_T>        := [10.4;11.4;0.1]
<1_Q>        := [270;374;1]
<1_V>        := [15.0;30.0;1.0/3.6]
<1_B>        := '0' | '1'
<1_Y>        := [3.25;4.25;0.05] | [6.50;7.50;0.05]

```

**Abbildung 3.11:** Globale Reaktionen: Exemplarische BNF-Definition der GP-Analyse

Die Genotypen der GP-basierten Optimierungsverfahren können in Baumstrukturen repräsentiert werden. Ein möglicher Baum, basierend auf der BNF-Definition der Abbildung 3.11, wird in der Abbildung 3.12 gezeigt. Die beiden Einzelereignisse einschließlich der Fahrzeugattribute sind zu erkennen.



**Abbildung 3.12:** Globale Reaktionen: Exemplarischer Ableitungsbaum

### 3.4.3 Evolutionäre Operatoren

Der Rekombinations- und der Mutationsoperator werden gemäß den Erläuterungen des Kapitels 2.2 verwendet. Im Ablauf des Evolutionären Algorithmus werden die Populationsgröße sowie die Wahrscheinlichkeiten der Rekombination und Mutation deterministisch angepasst. Es wird mit vergleichsweise großer Population, hoher Rekombination und geringer Mutation begonnen. Nach einer vorgegebenen Anzahl an Fitnesswertermittlungen wird die Populationsgröße gesenkt, die Rekombinationswahrscheinlichkeit

vermindert und zugleich die Mutationswahrscheinlichkeit erhöht (vgl. Kapitel 5). Die Wahrscheinlichkeitsverteilungen der p-Mutation werden für die nicht-terminierten Symbole der BNF-Definition entsprechend der Verteilungen zur Initial-Erzeugung von Individuen gewählt.

### 3.4.4 Lokale Reparaturen, Fitnesswertermittlung und Selektion

In der Messdatenanalyse globaler Reaktionen kann ein Gesamtereignis (GE) die Aufzeichnung mehrerer Sensoren umfassen. Der Einsatz einer höheren Anzahl an Sensoren kann zur Erfüllung gegebener Genauigkeitsanforderungen oder zur Identifikation von Fahrzeugen auf mehreren Fahrstreifen erforderlich sein. Bezug nehmend auf das Beispielszenario der Abbildung 3.9 würde die Identifikation der Fahrzeuge auf beiden Fahrstreifen die Berücksichtigung beider Dehnungen  $\Delta\epsilon_{c,1}$  und  $\Delta\epsilon_{c,2}$  erfordern.

Die Fitnesswertermittlung sieht als maßgebliches Optimierungsziel die Minimierung der Fehlerquadratsumme aus aufgezeichneten und berechneten Dehnungen vor:

$$e_{\text{fit}} = \frac{1}{L} \cdot \sum_{l=1}^L \left[ \frac{1}{K} \cdot \sum_{k=1}^K \left( \frac{\Delta\epsilon_{m,k} - \Delta\epsilon_{c,k}}{a_{\text{def}}} \right)^2 \right] \text{ mit } a_{\text{def}} \ll 1 \quad (3.2)$$

Mit: $e_{\text{fit}}$	Fitnesswert
$L$	Anzahl zu berücksichtigender Sensorsignale
$l$	Zähler der Sensorsignale
$K$	Anzahl diskreter Messwerte, die im betrachteten Zeitintervall enthalten sind
$k$	Zähler der Messwerte
$a_{\text{def}}$	Konstante des Nenners zur Erzielung von interpretierbaren Werten $e_{\text{fit}}$
$\Delta\epsilon_{m,k}$	Gemessener Dehnungswert
$\Delta\epsilon_{c,k}$	Berechneter Dehnungswert

Das Vorgehen der Fitnesswertermittlung gliedert sich in die drei aufeinander folgenden Schritte:

- 1) Erstellen des Phänotyps aus seinem Genotyp,
- 2) Durchführen lokaler Reparaturen, bei vorgenommenen Änderungen den Genotyp aus dem abgeänderten Phänotyp erzeugen und
- 3) Berechnung des Fitnesswertes auf Grundlage des Phänotyps.

Zur GP-Analyse von globalen Reaktionen beinhalten die lokalen Reparaturen die Überprüfung und Korrektur des Attributs der Fahrzeuggeschwindigkeit. Für Gesamtereignisse, die mehrere Einzelereignisse umfassen, werden hierzu die Fahrzeuge hinsichtlich der Fahrzeugabstände und möglicher Fahrzeugkolonnen geprüft. Da dicht aufeinander folgende Fahrzeuge keine wesentlichen Unterschiede in den Geschwindigkeiten aufweisen können, werden die einzelnen Geschwindigkeiten unter Zulassung einer definierten Toleranz auf den Mittelwert der Geschwindigkeiten der Fahrzeuge korrigiert. Im anschließenden Optimierungsprozess kann der EA die Geschwindigkeiten erneut variieren. Die lokalen Reparaturen ermöglichen hiermit die Berücksichtigung von Domänenwissen im Optimierungsprozess. Sie tragen zusätzlich zur BNF-Definition zur Gewährleistung der Realitätstreue der Lösungskandidaten bei.

Die Selektion der Eltern zur Erzeugung der Population der Nachfolgeneration erfolgt auf Grundlage der Fitnesswerte der Individuen. Individuen mit besseren Zielfunktionswerten werden mit höherer Wahrscheinlichkeit gewählt (vgl. Gleichungen 2.1 und 2.2). Die  $n_{\text{eli}}$  besten Individuen werden per Elitismus in die Nachfolgeneration übertragen.

## 3.5 Analyse lokaler Tragwerksreaktionen


### 3.5.1 Voraussetzungen

Lokale Tragwerksreaktionen sind von zeitlich kurzer Dauer und können den verursachenden Fahrzeugen direkt zugeordnet werden. Aufgrund dieser Eigenschaften wird die Ermittlung der Achsattribute Auftretenszeitpunkte  $t_i$  und Lasten  $Q_i$  ( $i$ : Index der Achse, vgl. auch Tabelle 3.2 und Abbildung 3.8) für einzelne Fahrzeuge vorgenommen.

Im Unterschied zur Analyse von gemessenen globalen Reaktionen sind ein Vorgehen in Zeitschritten und die Betrachtung von Zeitintervallen nicht erforderlich. Vielmehr werden die Messwerte eines festgelegten Zeitbereichs der Länge  $\bar{t}$  untersucht. Ein Zeitbereich beginnt bei dem Zeitwert  $t_{\min}$  und endet bei  $t_{\max} = t_{\min} + \bar{t}$ . Das entwickelte Verfahren sieht die Analyse der Aufzeichnung eines einzelnen Sensors vor.

Zur Veranschaulichung zeigt die Abbildung 3.13 in Ergänzung zur Abbildung 3.9 die Dehnungen  $\Delta\epsilon_{c,3}$  zur Überfahrt des 5-achsigen Sattelzugs im Fahrsteifen 1 und des 3-achsigen Lastkraftwagens im Überholverkehr. Die Dehnungen  $\Delta\epsilon_{c,3}$  stellen Reaktionen der Überbau-Längsrichtung dar und enthalten sowohl globale als auch lokale Anteile. Die globalen Anteile ergeben sich aus der Kombination von Reaktionen infolge der bei-

den Fahrzeuge. Die lokalen Anteile stellen die Folge einzelner Achslasten dar und sind für den Sattelzug deutlich zu erkennen. Der markierte Zeitbereich weist eine Länge  $\bar{t}$  von 1 s auf, beginnt bei dem Zeitwert  $t_{\min} = 9,5$  s und endet bei  $t_{\max} = 10,5$  s.



**Abbildung 3.13:** Analyse lokaler Reaktionen: Zeitbereich der Breite  $\bar{t}$

Die Ermittlung der Achseigenschaften eines Fahrzeugs erfordert die Kenntnis der Fahrzeugeigenschaften Auftretenszeitpunkt  $t_0$  und Geschwindigkeit  $v$ . Der Auftretenszeitpunkt wird benötigt, da der zu analysierende Zeitbereich, beschrieben durch  $t_{\min}$  und  $t_{\max}$ , in Abhängigkeit vom Wert  $t_0$  festgelegt wird. Die Geschwindigkeit wird zur Umrechnung der Dehnungen, welche im Rechenmodell für Lasten am Ort  $x$  ermittelt werden, auf die Zeit  $t$  verwendet.

Da die globalen Anteile der zu analysierenden Reaktionen gegebenenfalls die Kombination mehrerer Fahrzeuge darstellen, müssen zur Bestimmung der Achsattribute zusätzlich die Fahrzeuge berücksichtigt werden, welche sich zeitgleich mit dem betrachteten Fahrzeug auf dem Bauwerk aufhielten. Die Lasten weiterer Fahrzeuge, welche am Ort des untersuchten Sensors Reaktionen hervorriefen, müssen zur Dehnungsberechnung im Rechenmodell abgebildet werden.

Die Bestimmung der Achsattribute eines Fahrzeugs erfolgt daher nach Auswertung der globalen Reaktionen. Mit Kenntnis der Eigenschaften  $t_0$  und  $v$  für ein betrachtetes Fahrzeug sowie der Lasten weiterer auf dem Bauwerk vorhandener Fahrzeuge werden die Messwerte eines Zeitbereichs mit Hilfe eines auf Genetischer Programmierung basierenden Optimierungsverfahrens analysiert. Zur Unterstützung eines effizienten Optimie-

rungsprozesses wird ein künstliches Neuronales Netz hybrid eingebunden. Die Komplexität der Optimierungsaufgabe wird hierdurch verringert.

### 3.5.2 Achsdetektion mit Hilfe künstlicher Neuronaler Netze

Die Zusammenhänge zwischen erfassten, diskreten Messwerten und den verursachenden Einwirkungen können nicht direkt funktional modelliert werden. Eingeschränkte Genauigkeiten sowie vorhandene Toleranzen der eingesetzten Messelemente und verschmierte Messsignale infolge der Überlagerung unterschiedlicher Einwirkungen erfordern Methoden, welche tolerant gegenüber Ungenauigkeiten und Unsicherheiten sind. Künstliche Neuronale Netze (NN) weisen im Umgang mit komplexen und vage formulierten Daten ein hohes Potential auf. Für deren Einsatz ist die Kenntnis der funktionalen Zusammenhänge nicht erforderlich. Dennoch sind sie in der Lage, hochgradig nicht-lineare Zusammenhänge abzubilden.

Aufgrund ihrer hohen Lern- und Generalisierungsfähigkeit werden mehrschichtige feed-forward Systeme (Multilayer-Perceptrons) zur Analyse von erfassten lokalen Tragwerksreaktionen adaptiert. Die Systeme versprechen bei ausreichender Netzkapazität eine adäquate Fehlertoleranz gegenüber teilweise verrauschten realen Messwerten. Multilayer-Perceptrons haben sich bereits zur Lösung artverwandter praxisnaher Problemstellungen als probate Mittel erwiesen [GaFA94, Uhl02].


Mit ihrer Hilfe werden in einer Mustererkennung die Auftretenszeitpunkte  $t_i$  der Achsen ( $i$ : Index der Achse) einzelner Fahrzeuge abgeschätzt. Transparenz und Interpretierbarkeit des Inferenzprozesses sind hierbei nicht erforderlich.

In umfangreichen Parameterstudien (vgl. Kapitel 5) haben sich die mehrschichtigen Netzwerke als äußerst geeignet erwiesen, reale Messwerte zu analysieren. Im Rahmen der Untersuchungen wurden auch verschmierte Messsignale sehr geringer Amplituden betrachtet: Leichte Einzelachsen sowie einzelne Achsen von Achsgruppen (z.B. Doppel- oder Tripelachsen) unbeladener Anhänger oder Auflieger wurden hierbei sehr zuverlässig detektiert.

Das Vorgehen der NN-Analyse wird anhand der Abbildung 3.14 dargelegt. Der Abbildung sind die Dehnungen  $\Delta \varepsilon_{c,3}$  zur Überfahrt des 5-achsigen Sattelzugs zu entnehmen, welche bereits in der Abbildung 3.13 gezeigt wurden. Zur Erläuterung enthält die Abbildung die beispielhafte Darstellung eines Neuronalen Netzes, welches 9 Eingänge  $i$  und 1 Ausgang  $o$  umfasst. Zur Messdatenanalyse werden der Struktur des Neuronalen



Netzes entsprechend 9 diskrete Werte angelegt. Der Ausgang  $o$  gibt für einen Satz Eingänge jeweils die Anwesenheit einer Achse an. Die Auswertung eines vollständigen Zeitbereichs erfolgt durch ein Fortschreiten in der Taktung. Ein derartiges Vorgehen ist erforderlich, da die Zeitbereiche zu unterschiedlichen Fahrzeugen verschiedene Längen  $\bar{t}$  aufweisen und somit in ihrer Gesamtanzahl an diskreten Messwerten variieren. Die Zeitbereiche können nicht als Ganzes der NN-Analyse unterzogen werden, da Neuronale Netze stets eine fixe Anzahl an Eingängen besitzen. Die aktuell untersuchten Messwerte beginnen jeweils beim Zeitwert  $t_{in,min}$  und enden bei  $t_{in,max}$ .



**Abbildung 3.14:** Neuronales Netz: Grundsätzliches Vorgehen der Messdatenanalyse

Der  $k$ -te diskrete Messpunkt wird durch einen Messzeitpunkt  $t_{in,k}$  und -wert  $\Delta\epsilon_{m,in,k}$  beschrieben. Da NN eine fixe Struktur mit einer zu definierenden Anzahl an Eingängen aufweisen, ist bei einer konstanten Abtastfrequenz die Berücksichtigung des Zeitwerts  $t_{in,k}$  der einzelnen Messpunkte zur NN-Analyse unerheblich. Der Eingang  $i_k$  wird durch den jeweils normierten Dehnungswert  $\|\Delta\epsilon_{m,in,k}\|$  dargestellt. Die Normierung der Messwerte  $\Delta\epsilon_{m,in,k}$  erfolgt gemäß Gleichung 3.3 mit zu definierenden Grenzwerten der Mes-

sung  $\Delta\epsilon_{m,\min,\text{def}}$  und  $\Delta\epsilon_{m,\max,\text{def}}$  auf Eingänge  $0,0 \leq i_k \leq 1,0$ . Die Normierung erfüllt die Anforderung der Allgemeingültigkeit und Übertragbarkeit des Ansatzes. Ein entwickeltes NN kann hiermit – unabhängig von der betragsmäßigen Größenordnung erfasster Reaktionen – zur Analyse der Messdaten verschiedener Überbauten verwendet werden.

$$i_k = \frac{\|\Delta\epsilon_{m,\text{in},k}\|}{\|\Delta\epsilon_{m,\text{in},k} - \Delta\epsilon_{m,\min,\text{def}}\|} \cdot \frac{\|\Delta\epsilon_{m,\max,\text{def}} - \Delta\epsilon_{m,\min,\text{def}}\|}{\|\Delta\epsilon_{m,\max,\text{def}} - \Delta\epsilon_{m,\min,\text{def}}\|} \quad (3.3)$$

Der Ausgang  $o$  eines Neuronalen Netzes beschreibt die Existenz einer Achse für einen Datensatz. Eine Achse gilt als detektiert, wenn der reellwertige Ausgang  $o$  zu einem Satz Eingänge den Grenzwert  $o_{\text{ident}}$  übertrifft:

$$\text{Achsdetektion: } o \geq o_{\text{ident}} \quad (3.4)$$

Für eine detektierte Achse bestimmt sich der Auftretenszeitpunkt  $t_i$  ( $i$ : Index der Achse) gemäß Gleichung 3.5:

$$t_i = t_{\text{in,mid}} = t_{\text{in,min}} + 0,5 \cdot (t_{\text{in,max}} - t_{\text{in,min}}) \quad (3.5)$$

Mit:

$t_{\text{in,min}}$  minimaler Zeitwert der diskreten Messwerte, die an ein NN angelegt werden

$t_{\text{in,max}}$  maximaler Zeitwert der diskreten Messwerte, die an ein NN angelegt werden

(vgl. auch Abbildung 3.14)

Das NN-Lösungsverhalten wird in besonderem Maße durch die gewählte Anzahl der Eingänge, die Topologie und das Training bestimmt. Die drei Kriterien und deren jeweilige Bedeutung werden nachfolgend dargelegt.

### **Anzahl der Eingänge**

Ein eingesetztes Neuronales Netz soll für einen gegebenen Satz von Eingängen bestimmen, ob die Messung des Zeitraums  $t_{\text{in,min}}$  bis  $t_{\text{in,max}}$  die Folge genau einer oder keiner Achse mit dem Auftretenszeitpunkt  $t_{\text{in,mid}}$  gemäß Gleichung 3.5 darstellt. Zur Achsdetektion sind die extremalen Messpunkte infolge der einzelnen Achslasten von hoher Bedeutung. Wird der Bereich  $t_{\text{in,min}}$  bis  $t_{\text{in,max}}$  zu gering gewählt, so werden zur NN-Analyse gegebenenfalls wenige Nachbarbereiche der extremalen Messpunkte berücksichtigt. Die eindeutige Abbildung eines Messergebnisses infolge einer Achslast erfordert die Aufnahme von hinreichend großen Nachbarbereichen. Die Nachbarberei-

che dürfen wiederum nicht zu groß gewählt werden, da hierdurch ggf. ein Messergebnis untersucht wird, welches sich infolge von mehreren Achslasten ergab.

Da in die NN-Analyse ausschließlich die erfassten Dehnungswerte  $\Delta\epsilon_{m,in,k}$  nicht jedoch die Zeitwerte  $t_{in,k}$  der diskreten Messpunkte eingehen, wird die Größe der Nachbargbereiche durch die Anzahl der NN-Eingänge bestimmt. Überlegungen zur erforderlichen Anzahl an Eingängen müssen demnach die Abtastfrequenz eines zu analysierenden Messsignals, die minimal möglichen Achsabstände und maximale Fahrzeuggeschwindigkeiten berücksichtigen. Die Anzahl der Eingänge bestimmt somit maßgeblich, wie viel Information über ein Messergebnis der NN-Auswertung zur Verfügung gestellt wird. Das Merkmal hat daher einen hohen Einfluss auf das NN-Lösungsverhalten.

### ***Topologie***

Mehrschichtige Neuronale Netze erfordern die Verwendung nichtlinearer Aktivierungsfunktionen. Aufgrund der guten mathematischen Handhabbarkeit [Adam03] wird die Fermi-Funktion gemäß Gleichung 2.7 eingesetzt. Propagierungs- und Ausgabefunktion sind die Standardfunktionen der gewichteten Summe (Gleichung 2.5) und der Identität (Gleichung 2.9). Der sinnvolle Aufbau der verdeckten Schichten und die notwendige Anzahl an inneren Neuronen werden im Rahmen von umfangreichen Parameterstudien (vgl. Kapitel 5) untersucht. Grundsätzlich werden vollverknüpfte feedforward Netze verwendet, da sich diese zur Lösung von artverwandten Problemen bereits als geeignet erwiesen haben [GaFA94, Uhl02].

Die angewandten NN-Topologien, insbesondere die gewählte Aktivierungsfunktion, ergeben reellwertige Ausgänge  $0,0 \leq o \leq 1,0$ . Das Erfordernis der Definition einer Bedingung gemäß Gleichung 3.4 wird hiermit verdeutlicht.

### ***Training***

Der Backpropagation-Algorithmus repräsentiert das Lernverfahren der Multilayer-Perceptrons. Um bekannte Nachteile des konventionellen Ansatzes zu überwinden, wird das modifizierte Verfahren Rprop (Resilient Backpropagation) verwendet. Im Vergleich mit weiteren Lernverfahren zeigte Rprop hinsichtlich der erforderlichen Trainingszeit die beste Performanz [Zell03]. Das Training der Netzwerke wird mit Hilfe des Simulators „JavaNNS“, der unter Leitung von Zell an der Universität Stuttgart entwickelt wurde und über die Internetseiten des Lehrstuhls für Rechnerarchitektur der Universität Tübingen bezogen werden kann, durchgeführt.

Das Training erfolgt mit aufbereiteten Datensätzen, die aus den am Brückenbauwerk erfassten Messdaten erstellt werden. Zweckmäßigerweise wird die Messung durch eine Videoaufzeichnung begleitet. Hiernach ist es möglich, den gewonnen Messdaten direkt die Fahrzeuge zuzuweisen, welche die Aufzeichnung hervorriefen. Die Trainingsdatensätze setzen sich jeweils aus den Eingängen  $i$  und dem Ausgang  $o$  zusammen. Es werden positive und negative Datensätze unterschieden. Ein positiver Datensatz weist für  $t_{in,mid}$  den extremalen Messwert infolge einer Achslast auf, der Ausgang wird daher mit 1 belegt. Ein negativer Datensatz enthält keine Achse, der Ausgang wird zu 0 gesetzt. Das NN-Training erfolgt demnach mit Datensätzen, die entweder einen Ausgang von genau 1 (Achse) oder genau 0 (keine Achse) aufweisen, in Abhängigkeit davon, ob für  $t_{in,mid}$  der extremale Messwert infolge einer Achslast vorliegt.

Die Neuronalen Netze werden zwangsläufig auf eine limitierte Anzahl an Datensätzen trainiert. Ein Neuronales Netz kann daher kaum sämtliche möglichen Eventualitäten abdecken. Folglich kann ein eingesetztes Neuronales Netz in der Anwendung auf Datensätze, welche nicht zum Training verwendet wurden, auch Achsen für Eingänge detektieren, die für  $t_{in,mid}$  nicht den extremalen Messwert infolge einer Achslast aufweisen. Diese Achsen können falsch detektiert sein oder im unmittelbaren Umfeld einer tatsächlich vorhandenen Achse vorliegen. Diesbezügliche Untersuchungen sind dem Kapitel 5 zu entnehmen.

Die Übertragung der Erkenntnisse hinsichtlich der NN-Messdatenanalyse auf die Auswertung der globalen Reaktionen ist nicht zweckmäßig. Globale Reaktionen sind geprägt durch die starke Überlagerung der Reaktionen infolge einzelner Fahrzeuge. Aufgrund der stark variierenden Fahrzeugabstände, -gesamtgewichte und -geschwindigkeiten ist die NN-Analyse dieser Reaktionen wenig sinnvoll.

### 3.5.3 Initialisierung


Zu Beginn der Analyse von erfassten lokalen Reaktionen wird ein trainiertes Neuronales Netz auf die Messwerte des betrachteten Zeitbereichs angewandt. Für ein untersuchtes Fahrzeug werden Auftretenszeitpunkte  $t_i$  der Achsen ( $i$ : Index der Achse) detektiert. Auf Grundlage der zu den Zeitwerten  $t_i$  zugehörigen Messwerte werden Achslasten  $Q_i$  deterministisch abgeschätzt.

Im GP-basierten Optimierungsverfahren zur Analyse der lokalen Reaktionen werden die Phänotypen im Wesentlichen durch die Attribute  $t_i$  und  $Q_i$  der Achsen eines Fahrzeugs

beschrieben (vgl. auch Abbildung 3.8). Die mit Hilfe des Neuronalen Netzes für  $t_i$  und  $Q_i$  erhaltenen Ergebnisse repräsentieren somit eine erste Lösung der Optimierungsaufgabe. Dieses Domänenwissen soll im Rahmen des GP-Optimierungsverfahrens berücksichtigt werden. Zweckmäßigerweise erfolgt daher die Generierung der Initial-Population basierend auf den bereits gewonnenen Ergebnissen.

Entsprechend der Ausführungen zur Initial-Erzeugung der Individuen des GP-Verfahrens zur Analyse der globalen Reaktionen wird die BNF-Definition auf der Grundlage des vorhandenen Vorwissens erstellt. Die numerischen Größen  $t_i$  und  $Q_i$  werden mit Hilfe des nicht-terminierten Wertebereich-Symbols in der BNF-Definition abgebildet. Die zielgerichtete Initialisierung der Attribute wird durch die Definition von Wahrscheinlichkeitsverteilungen für die Wertebereich-Symbole bewirkt. Unter Verwendung der Gauß-Verteilung wird der Erwartungswert  $\mu$  gleich dem Ergebniswert des jeweiligen Attributs gesetzt. Die Abweichungen  $\sigma$  werden für die Achsattribute fix vorgegeben. Die Initialisierung eines numerischen Werts erfolgt schließlich unter Beachtung der durch die Gauß-Verteilungen definierten, angestrebten Wahrscheinlichkeiten.

Die umfangreiche Evaluierung unterschiedlicher Neuronaler Netze an einer hohen Anzahl von Testdatensätzen (vgl. Kapitel 5) hat gezeigt, dass trainierte Neuronale Netze entweder die richtige oder eine höhere Anzahl an Achsen für die Fahrzeuge detektieren. Eine geringere als die tatsächlich vorhandene Anzahl von Achsen wurde nicht angegeben. Diese Ergebnisse bezüglich des NN-Verhaltens werden in der Erstellung der BNF-Definition berücksichtigt und anhand der Abbildung 3.15 erläutert.



**Abbildung 3.15:** BNF-Definition der Achsen und Angaben zur  $p$ -Initialisierung

Gemäß Abbildung 3.15 sei das nicht-terminierte Symbol Achsen  $A_S$  durch eine bis sieben Achsen  $A$  definiert. Das Symbol  $A$  (nicht-terminiert) enthält hierbei die Attribute Auftretenszeitpunkt und Last der Achse. Die Alternativen des Symbols  $A_S$  liegen geordnet vor. Mit Hilfe der Variablen  $j$  wird die Nummer der Alternativen bezeichnet. Das Ergebnis der NN-Auswertung sei die Detektion von insgesamt 4 Achsen. Zur p-Initialisierung wird der Erwartungswert  $\mu$  der Normalverteilung auf die Alternative  $j = 4$  gelegt. Zugleich werden Abweichungen links  $\sigma_l$  und rechts  $\sigma_r$  derart definiert, dass die Anzahl der Achsen mit erhöhter Wahrscheinlichkeit vermindert und mit geringerer Wahrscheinlichkeit vergrößert wird. In der Abbildung wurde der Wert  $\sigma_l$  zu 2 und  $\sigma_r$  zu 1 gewählt. Es ist zu erkennen, dass mit Hilfe der abgewandelten Normalverteilung die Vorgabe einer angestrebten „Optimierungsrichtung“ ermöglicht wird.

Zur realitätsnahen Abbildung der Fahrzeuge mit Hilfe einer BNF-Definition werden die zu optimierenden Achseigenschaften Achsregionen zugewiesen. Eine Achsregion erstreckt sich über einen gegebenen Zeitraum und beinhaltet eine oder mehrere Achsen. Die Feststellung der Achsregionen erfolgt auf Basis der Ergebnisse bezüglich der Auftretenszeitpunkte der Achsen aus der vorherigen NN-Analyse. Mit Hilfe der Achsregionen ist es möglich, reale Einzelachsen und Achsgruppen zu unterscheiden.

Darüber hinaus wird in der BNF-Definition zusätzlich zum Attribut  $y$  der Analyse erfasster globaler Reaktionen (vgl. Abbildung 3.8) ein Korrekturwert  $\Delta y$  berücksichtigt. Der Wert ist erforderlich, da lokale Reaktionen in besonderem Maße sensitiv bezüglich des Querabstands der Fahrzeuge sind.

Für den 5-achsigen Sattelzug des Zeitbereichs der Abbildung 3.13 enthält die Abbildung 3.16 eine exemplarische BNF-Definition.

Ausgehend vom Startsymbol  $S$  werden Lösungskandidaten zunächst durch den Korrekturwert  $D_{TY}$  ( $\Delta y$ ) und Achsregionen  $AR_G$  beschrieben. Die Achsregionen werden jeweils durch eine Last  $Q$  und Achsen  $A_S$  definiert. Die Last  $Q$  kennzeichnet die mittlere Last der zugewiesenen Achsen. Die Achsen  $A_S$  enthalten zur Modellierung von Einzelachsen und Achsgruppen eine oder mehrere Achsen  $A$ . Eine Achse  $A$  wird durch eine Abweichung  $Dev$  und einen Auftretenszeitpunkt  $T$  beschrieben. Mit Hilfe des Symbols  $Dev$  werden Abweichungen einzelner Achslasten einer Gruppe zum Wert  $Q$  abgebildet. Insgesamt sind 3 Achsregionen zu erkennen. Hierbei werden mit Hilfe von  $AR_{G1}$  die erste Einzelachse (die Lenkachse) des Sattelzugs, mit  $AR_{G2}$  die zweite Achse (die angetriebene Achse) und mit  $AR_{G3}$  die Achsen der Tripelachse des Aufliegers modelliert.

```

<S>      := <DtY> <ARg>
<Q>      := [49;134;1]
<Dev>    := [-0.20;+0.20;0.01]
<DtY>    := [-0.30;+0.30;0.01]
<ARg>    := <ARg1> <ARg2> <ARg3>
<ARg1>   := <Q> <As1>
<ARg2>   := <Q> <As2>
<ARg3>   := <Q> <As3>
<As1>    := <A1> | <A1> <A1>
<As2>    := <A2> | <A2> <A2>
<As3>    := <A3> | <A3> <A3> | <A3> <A3> <A3> | <A3> <A3> <A3> <A3>
<A1>     := <Dev> <T1>
<A2>     := <Dev> <T2>
<A3>     := <Dev> <T3>
<T1>     := [9.692;9.752;0.002]
<T2>     := [9.880;9.940;0.002]
<T3>     := [10.024;10.216;0.002]

```

**Abbildung 3.16:** Lokale Reaktionen: Exemplarische BNF-Definition der GP-Analyse

Die dargestellte BNF-Definition weist eine klare Struktur von mehreren aufeinander folgenden Textbausteinen auf. Die im Rahmen der NN-Analyse ermittelte Anzahl von Achsregionen bestimmt den Umfang der Bildungsvorschrift. Die BNF-Definition ist daher geeignet, zur Analyse von kontinuierlich erfassten Messgrößen automatisiert erstellt zu werden. Die generische Struktur geht jedoch mit Einschränkungen in der wirklichkeitsgetreuen Abbildung der Fahrzeuge einher. Für Einzelachsen und Achsen von Achsgruppen kann das Folgende festgestellt werden:

- Aufgrund der gewählten Definition des Symbols  $\mathbf{A}$  wird auch Einzelachsen eine Abweichung  $\mathbf{Dev}$  zum Mittelwert ihrer Achslast  $\mathbf{Q}$  zugewiesen. Zur eindeutigen Beschreibung der Lasten von Einzelachsen wäre die Berücksichtigung der Abweichung nicht erforderlich. Zur automatisierten Generierung der Bildungsvorschriften sowie zur Modellierung der Achslasten von Achsgruppen ist die Größe jedoch unentbehrlich.
- Das Symbol  $\mathbf{A}$  enthält den Auftretenszeitpunkt  $\mathbf{T}$  der Achse. Hierdurch erhalten die einzelnen Achsen von Achsgruppen in einem Genotyp jeweils eigene Auftretenszeitpunkte. Der gleichmäßige Abstand der Achsen einer Gruppe kann nicht sichergestellt werden. Im Phänotyp wird daher eine Korrektur der Achsabstände im Rahmen von lokalen Reparaturen vorgenommen. Die gewählte Repräsentation gewährleistet jedoch, dass sämtliche Achsen stets im zulässigen Zeitraum der jeweiligen Achsregion angelegt und behandelt werden.

Die Abbildung 3.17 zeigt eine alternative BNF-Definition, welche die zuvor benannten Einschränkungen teilweise nicht aufweist. Die Bildungsvorschrift enthält ebenfalls definierte Textbausteine und erfüllt die Anforderung, automatisiert generierbar zu sein.

$\langle S \rangle$	$:= \langle DtY \rangle \langle ARg \rangle$
$\langle Q \rangle$	$:= [49;134;1]$
$\langle Dev \rangle$	$:= [-0.20;+0.20;0.01]$
$\langle DtY \rangle$	$:= [-0.30;+0.30;0.01]$
$\langle DtT \rangle$	$:= [0.036;0.114;0.002]$
$\langle ARg \rangle$	$:= \langle ARg1 \rangle \langle ARg2 \rangle \langle ARg3 \rangle$
$\langle ARg1 \rangle$	$:= \langle A1 \rangle \mid \langle AGp1 \rangle$
$\langle ARg2 \rangle$	$:= \langle A2 \rangle \mid \langle AGp2 \rangle$
$\langle ARg3 \rangle$	$:= \langle A3 \rangle \mid \langle AGp3 \rangle$
$\langle A1 \rangle$	$:= \langle T1 \rangle \langle Q \rangle$
$\langle A2 \rangle$	$:= \langle T2 \rangle \langle Q \rangle$
$\langle A3 \rangle$	$:= \langle T3 \rangle \langle Q \rangle$
$\langle AGp1 \rangle$	$:= \langle A1 \rangle \langle DtT \rangle \langle As1 \rangle$
$\langle AGp2 \rangle$	$:= \langle A2 \rangle \langle DtT \rangle \langle As2 \rangle$
$\langle AGp3 \rangle$	$:= \langle A3 \rangle \langle DtT \rangle \langle As3 \rangle$
$\langle As1 \rangle$	$:= \langle Dev \rangle \langle Dev \rangle$
$\langle As2 \rangle$	$:= \langle Dev \rangle \langle Dev \rangle$
$\langle As3 \rangle$	$:= \langle Dev \rangle \langle Dev \rangle \mid \langle Dev \rangle \langle Dev \rangle \langle Dev \rangle \mid \langle Dev \rangle \langle Dev \rangle \langle Dev \rangle \langle Dev \rangle$
$\langle T1 \rangle$	$:= [9.692;9.752;0.002]$
$\langle T2 \rangle$	$:= [9.880;9.940;0.002]$
$\langle T3 \rangle$	$:= [10.024;10.216;0.002]$

**Definition des Symbols  $DtT$  (Zeitabstand der Achsen einer Gruppe):**

Minimaler Abstand der Achsen einer Gruppe:  
1,10 m / 30 m/s = 0,037 s

Maximaler Abstand der Achsen einer Gruppe:  
1,70 m / 15 m/s = 0,113 s

Die Werte werden ab- bzw. aufgerundet und der Schrittweite (hier: 0,002) angepasst.

**Abbildung 3.17:** Lokale Reaktionen: Alternative BNF-Definition der GP-Analyse

In der BNF-Definition werden die Achsen, wie auch zuvor, Achsregionen  $ARg$  zugeordnet. Für die Symbole gelten die vorherigen Erläuterungen. Im Gegensatz zur BNF-Definition der Abbildung 3.16 werden Einzelachsen  $A$  und Achsgruppen  $AGp$ , die mindestens zwei Achsen umfassen, direkt unterschieden. Die Achsgruppen werden in objektorientierter Weise abgebildet (siehe Abbildung 3.18): Das Symbol  $AGp$  beinhaltet eine Achse  $A$  und übernimmt („erbt“) deren Eigenschaften. Die Achsgruppe  $AGp$  wird zusätzlich durch die Größe  $DtT$  definiert. Mit Hilfe des Symbols  $DtT$  wird der gleichmäßige Zeitabstand der Achsen einer Gruppe beschrieben.

Für eine Einzelachse  $A$  kennzeichnet  $Q$  die Last und  $T$  den Auftretenszeitpunkt. Im Falle einer Achsgruppe  $AGp$  bezeichnet  $Q$  den Mittelwert der Achslasten; zur Definition der Größe  $T$  bestehen mehrere Möglichkeiten:  $T$  könnte beispielsweise einen gemittelten oder den Auftretenszeitpunkt der ersten Achse darstellen. Die Achsanzahl einer Gruppe folgt aus der Anzahl der Abweichungen  $Dev$ , welche ein Symbol  $As$  aufweist. Die gewählte Repräsentation kann für die Achsgruppen nicht gewährleisten, dass Auftretenszeitpunkte stets im zulässigen Zeitraum der Achsregionen behandelt werden. In Abhän-



gigkeit vom Zeitwert  $T$ , der Anzahl an Achsen einer Gruppe und des Abstands  $D_{tT}$  können einzelne Achsen einer Gruppe unzulässige Auftretenszeitpunkte annehmen. Die Genotypen wären nicht gültig und müssten im Optimierungsprozess verworfen werden.

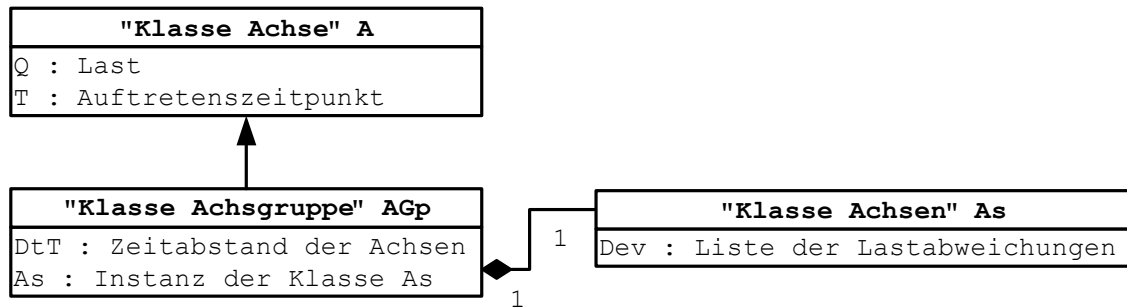


Abbildung 3.18: Objektorientierte Abbildung der Symbole A und AGp

Die generische Struktur führt somit auch bei dieser BNF-Definition zu Beeinträchtigungen. Da im Optimierungsprozess Genotypen ggf. ungültig und verworfen werden, sind trotz realitätsnäherer Repräsentation der Einzelachsen und Achsgruppen die Einschränkungen im Vergleich zur Bildungsvorschrift der Abbildung 3.16 gravierender. Nachfolgend werden daher BNF-Definitionen vom Typ der Abbildung 3.16 betrachtet. Die Abbildung 3.19 zeigt einen möglichen Genotyp, der auf Basis der BNF-Definition der Abbildung 3.16 generiert wurde.

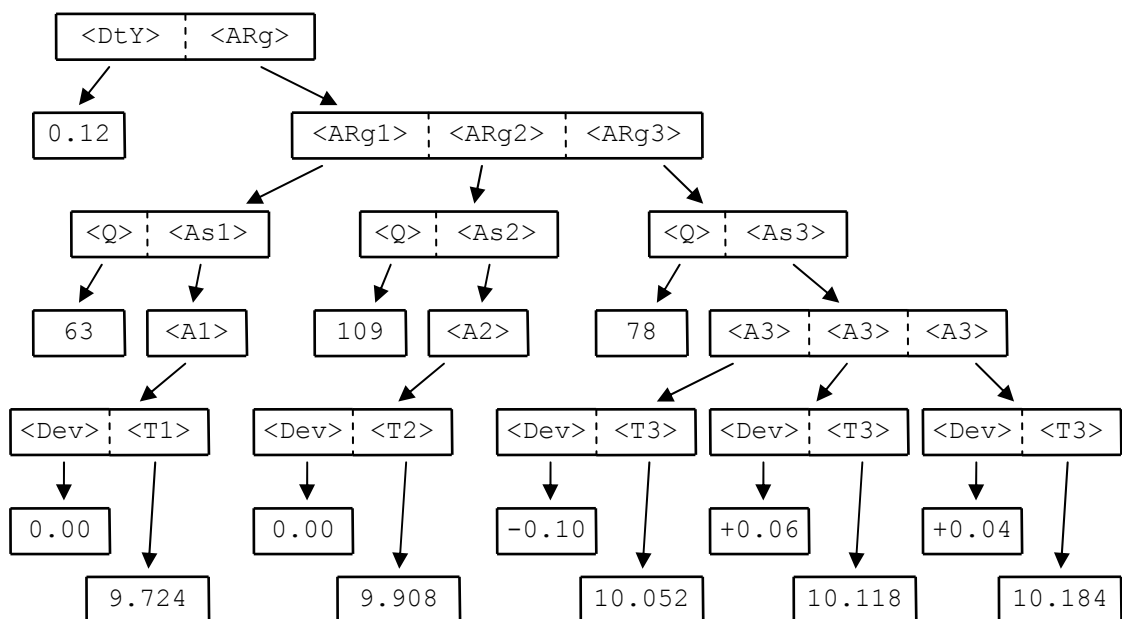


Abbildung 3.19: Lokale Reaktionen: Exemplarischer Ableitungsbaum

### 3.5.4 Evolutionäre Operatoren

Die evolutionären Operatoren werden entsprechend der Ausführungen des Kapitels 2.2 angewendet. Die Parameter des Evolutionären Algorithmus (Größe der Population, Rekombinations- und Mutationswahrscheinlichkeiten) werden deterministisch adaptiert (vgl. Erläuterungen und Untersuchungen im Kapitel 5). Die p-Mutation erfolgt mit Hilfe der Wahrscheinlichkeitsverteilungen der Initialisierung.

### 3.5.5 Lokale Reparaturen, Fitnesswertermittlung und Selektion

Im Unterschied zur Analyse von gemessenen globalen Reaktionen werden die Messwerte eines einzelnen Sensors untersucht. Zur Anwendung des entwickelten Verfahrens werden zweckmäßigerweise mehrere Sensoren zur Erfassung der lokalen Reaktionen installiert (vgl. auch  $\Delta\epsilon_{c,3}$  und  $\Delta\epsilon_{c,4}$  der Abbildung 3.1). Der Analyse wird das Messsignal unterzogen, dessen Sensor den einwirkenden Radlasten am nächsten ist und die Lasten am deutlichsten erkennen lässt. Da die Auswertung der lokalen Reaktionen an die der globalen Reaktionen anschließt, kann zur Bestimmung des nächstgelegenen Sensors das Attribut des Fahrzeug-Querabstands  $y$  herangezogen werden.

Das Optimierungsziel besteht im Wesentlichen in der Minimierung der Fehlerquadratsumme aus aufgezeichneten und berechneten Dehnungen (Gleichung 3.6). Darüber hinaus gehen in die Fitnesswertermittlung zwei Straffaktoren  $f_{\text{pen},1}$  und  $f_{\text{pen},2}$  ein. Der Faktor  $f_{\text{pen},1}$  berücksichtigt die Unterschreitung eines angestrebten minimalen Achsabstands und  $f_{\text{pen},2}$  die Unterschreitung einer angestrebten Anzahl an Achsen. Die Faktoren werden jeweils ermittelt, indem der angestrebte Wert (Index „int“) ins Verhältnis zum aktuellen Wert (Index „pre“) gesetzt wird. Statt einer BNF-Definition, die eine scharfe Begrenzung auf Werte, welche größer als die angestrebten sind, vornimmt, wird hierdurch eine Lösungsannäherung von zwei statt von einer Seite unterstützt. Mit Hilfe des Faktors  $f_{\text{pen},2}$  wird zudem das Lösungsverhalten berücksichtigt, wonach ein trainiertes NN die richtige oder eine höhere Anzahl von Achsen detektiert. In die Gütebeurteilung der Lösungskandidaten fließt hiermit Domänenwissen ein. Das GP-Optimierungsverfahren gewinnt mit Hilfe der Straffaktoren deutlich an Flexibilität und Leistungsstärke.

$$e_{\text{fit}} = f_{\text{pen},1} \cdot f_{\text{pen},2} \cdot \frac{1}{K} \cdot \sum_{k=1}^K \left( \frac{\Delta\epsilon_{m,k} - \Delta\epsilon_{c,k}}{a_{\text{def}}} \right)^2 \quad \text{mit } a_{\text{def}} \ll 1 \quad (3.6)$$

$$f_{\text{pen},1} = x_{\text{min,int}} / x_{\text{min,pre}} \geq 1,0 \quad \text{und} \quad f_{\text{pen},2} = n_{\text{int}} / n_{\text{pre}} \geq 1,0$$

Mit: $e_{\text{fit}}$	Fitnesswert
$f_{\text{pen},1}$	Straffaktor zur Berücksichtigung der Unterschreitung des Werts $x_{\text{int},\text{min}}$
$f_{\text{pen},2}$	Straffaktor zur Berücksichtigung der Unterschreitung des Werts $n_{\text{int}}$
$K$	Anzahl diskreter Messwerte, die im untersuchten Zeitbereich enthalten sind
$k$	Zähler der Messwerte
$x_{\text{min},\text{int}}$	Angestrebter minimaler Achsabstand (zu definierende Konstante)
$x_{\text{min},\text{pre}}$	Vorhandener minimaler Achsabstand
$n_{\text{int}}$	Angestrebte Anzahl an Achsen (basierend auf den Ergebnissen des NN)
$n_{\text{pre}}$	Vorhandene Anzahl an Achsen
$a_{\text{def}}$	Konstante des Nenners zur Erzielung von interpretierbaren Werten $e_{\text{fit}}$
$\Delta\epsilon_{\text{m},k}$	Gemessener Dehnungswert
$\Delta\epsilon_{\text{c},k}$	Berechneter Dehnungswert

Wie auch im GP-Verfahren zur Analyse der globalen Tragwerksreaktionen umfasst die Fitnesswertermittlung die drei Schritte:

- 1) Erzeugung des Phänotyps aus dem Genotyp,
- 2) Ausführen von lokalen Reparaturen, bei vorgenommenen Änderungen den Genotyp erneut generieren und
- 3) Ermittlung des Fitnesswerts für den Phänotyp gemäß Gleichung 3.6.

Die lokalen Reparaturen sehen die Überprüfung und – sofern erforderlich – die Korrekturen der Abstände der Achsen von Achsgruppen vor. BNF-Definitionen, welche dem Typ der Abbildung 3.16 entsprechen, können nicht gewährleisten, dass die Achsen einer Gruppe einen gleichen Abstand zueinander aufweisen. Enthält eine Achsregion drei Achsen oder mehr, so werden deren Abstände geprüft und die Auftretenszeitpunkte der einzelnen Achsen derart abgeändert, dass sich gleiche Abstände ergeben. Hierdurch wird Vorwissen berücksichtigt und die wirklichkeitsgetreue Modellierung der Fahrzeuge sichergestellt.

Die Selektion wird auf Grundlage der berechneten Fitnesswerte durchgeführt (vgl. Gleichungen 2.1 und 2.2). Im Rahmen eines Elitismus wird eine definierte Anzahl bester Individuen unverändert in die Nachfolgeneration übernommen.

## 3.6 Zusammenführung der entwickelten Methoden

### 3.6.1 Allgemeines

Die entwickelten Methoden werden im IIM-Algorithmus integriert. Nachfolgend werden die Anforderungen definiert, welche eine Implementierung des Algorithmus erfüllen soll. Die wichtigsten Elemente einschließlich deren Eigenschaften und Operationen werden erläutert und in einem UML (Unified Modeling Language) Diagramm zusammengeführt. Unter dem Begriff „Element“ ist im objektorientierten Sinne eine Klasse zu verstehen, die „Eigenschaften“ beschreiben deren Attribute und die „Operationen“ kennzeichnen die Methoden bzw. Funktionen der Klasse. Der grundlegende Ablauf der Messdatenanalyse in Zeitschritten wird dargestellt. Die Unterscheidung der Analyse von globalen und lokalen Tragwerksreaktionen sowie die Aufrufe der jeweiligen Optimierungskerne werden verdeutlicht. Anhand eines Ablaufdiagramms wird unter anderem veranschaulicht, aufgrund welcher Bedingungen Fahrzeuge im Optimierungsprozess verworfen bzw. identifiziert werden.

In der Beschreibung der wesentlichen Elemente werden ausschließlich die Funktionalitäten behandelt, die im unmittelbaren Zusammenhang mit den Optimierungsverfahren zur Analyse der globalen und der lokalen Reaktionen stehen. Die Methoden und Attribute, die zur weiteren Verarbeitung von evolutionär optimierten Größen dienen, sind nicht Gegenstand der Erläuterungen. Um den eindeutigen Bezug zu den globalen bzw. den lokalen Reaktionen zu gewährleisten, werden für die Variablen die Indizes „glo“ und „lok“ gesetzt. In diesem Abschnitt werden Bezeichnungen gewählt, die in diesem Kapitel bereits Anwendung fanden. Mögliche Klassenbezeichnungen werden im Text in gesonderter Schriftart angezeigt.

### 3.6.2 Wesentliche Elemente: Funktionalitäten und Eigenschaften

#### *Sensor*

Ein am Bauwerk installierter Sensor wird mit Hilfe des Elements *Sensor* abgebildet. Das Element besitzt einen Zugriff auf die Messdaten des realen Sensors. Über eine Schnittstelle ist die Berechnungskomponente, im Allgemeinen ein Finite Elemente (FE) Kern, angeschlossen. Der FE-Kern ermittelt für eine gegebene Belastungssituation im Rechenmodell die Dehnungen am Ort des Sensors. Die Klasse *Sensor* muss über Methoden verfügen, welche die erfassten bzw. die berechneten Dehnungen zurückgeben.

### ***Fahrzeug***

`Fahrzeug` beinhaltet als Objekt ein Fahrzeug einschließlich sämtlicher erforderlicher Attribute. Die Einzelachsen eines Fahrzeugs werden durch das Element `Achse` repräsentiert. Das Element enthält die Attribute `Achslast` und `Auftretenszeitpunkt` der Achse. Achsgruppen werden mit Hilfe der Klasse `Achsgruppe` abgebildet. `Achsgruppe` erweitert das Element `Achse` und übernimmt dessen Eigenschaften. In Übereinstimmung mit der grundsätzlichen BNF-Definition der Abbildung 3.16 ist in `Achsgruppe` das Attribut der `Achslast` als die mittlere Last der Achsen zu definieren. Die Abweichungen von einzelnen Achslasten zum Mittelwert sind in geeigneter Weise vorzuhalten. Identifizierte Fahrzeuge werden im Element `Fahrzeuge` abgelegt.

### ***Gesamtereignis, Einzelereignis***

Ein `EinzelEreignis` enthält genau ein `Fahrzeug` und zusätzliche Attribute, welche die Optimierungsprozesse erfordern. Die untersuchten Einzelereignisse werden im Element `GesamtEreignis` vorgehalten. Die Klasse `GesamtEreignis` muss Mechanismen bereitstellen, die es ermöglichen, Einzelereignisse zum Gesamtereignis hinzuzufügen bzw. zu entfernen. Zur Fitnesswertermittlung muss die Klasse Methoden berücksichtigen, die zu einer gegebenen Belastungssituation (`Fahrzeuge` der Einzelereignisse) und zu dem Ort eines realen Sensors berechnete Dehnungen zurückgeben.

### ***Abbildung der Phänotypen***

Die Phänotypen der evolutionären Optimierungsprozesse werden mit Hilfe der Elemente `PhaenotypGlobal` und `PhaenotypLokal` beschrieben. Diese erweitern das Element `GesamtEreignis` und „erben“ dessen Funktionalitäten und Eigenschaften. `PhaenotypGlobal` repräsentiert die Phänotypen des EA-Kerns der globalen Reaktionen, wohingegen `PhaenotypLokal` die der lokalen Reaktionen darstellt. Zur Feststellung der Auftretenszeitpunkte einzelner Fahrzeugachsen erfordert die Klasse `PhaenotypLokal` einen Zugriff auf die Neuronale Netz Komponente. Beide Phänotyp-Klassen müssen Methoden aufweisen, welche die Transformation vom Phänotyp in den zugehörigen Genotyp und umgekehrt gestatten. Derartige Transformationen sind zur Fitnesswertermittlung sowie zur Durchführung der lokalen Reparaturen erforderlich.

### ***Einstellungen, Sprachdefinitionen***

Allgemeine Einstellungen zum jeweiligen Analyseverfahren werden in `SetupGlobal` und `SetupLokal` vorgehalten. Zweckmäßigerweise erfolgt die Initialisierung der Backus-Naur Form (BNF)-Definitionen mit Hilfe dieser Elemente. Die entsprechenden Methoden der zugehörigen Klassen müssen den besonderen Belangen zur Berücksichtigung von Domänenwissen in der Erstellung der BNF-Definitionen gerecht werden: Die BNF-Definition zur Analyse der globalen Reaktionen ist basierend auf den Einzelereignissen des vorherigen Zeitschritts und möglicher Folgefahrzeuge anzulegen; die Sprachdefinition der lokalen Reaktionen ist unter Beachtung der Ergebnisse des Neuronalen Netzes bezüglich der Auftretenszeitpunkte der Fahrzeugachsen zu entwickeln. `SetupGlobal` und `SetupLokal` beinhalten zudem die jeweils zugeordneten Sensoren (Typ `Sensor`) und verweisen somit auf die auszuwertenden Messdaten. Die Elemente `PhaenotypGlobal` und `PhaenotypLokal` erhalten einen Zugriff auf das jeweils zugehörige Element `SetupGlobal` bzw. `SetupLokal`.

### ***Steuerung und Verknüpfung der Prozesse***

Die Steuerung und Verknüpfung der einzelnen Prozesse wird mit Hilfe des Elements `Steuerung` vorgenommen. Das Element enthält das statische Gesamtereignis `GEstat` und die im Rahmen der Messdatenanalyse identifizierten Fahrzeuge. Es besitzt zudem den Zugriff auf die GP-Optimierungskomponente.

Aufgrund der aufgeführten Anforderungen und Überlegungen ergibt sich das in der Abbildung 3.20 auszugsweise dargestellte Klassendiagramm.

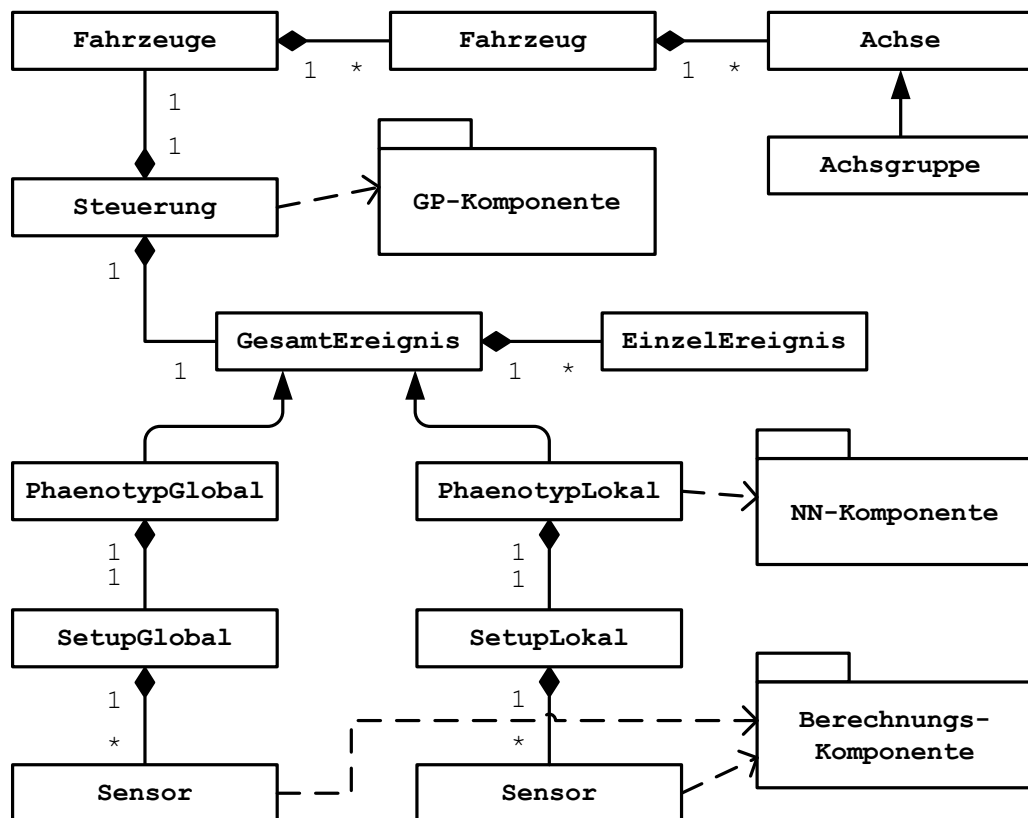


Abbildung 3.20: UML-Klassendiagramm der Verkehrslastidentifikation

### 3.6.3 Prinzipieller Ablauf der Messdatenanalyse

Funktionalitäten der Klasse `Steuerung` und hiermit wesentliche Aspekte des Ablaufs der Messdatenanalyse werden nachfolgend anhand der Struktogramme der Abbildung 3.21 erläutert.

Die Messdatenanalyse erfolgt innerhalb einer Schleife über Zeitschritte  $\Delta t_{\text{glo}}$ , bis das Ende der Messdaten erreicht wird. Zur Erzielung eines effizienten Analyseverfahrens werden Zeitabschnitte ohne Verkehr in den Messungen detektiert und vom Optimierungsprozess ausgeschlossen. Das statische Gesamtereignis  $\text{GE}_{\text{stat}}$  enthält somit sowohl zu Beginn als auch zu einem späteren Zeitpunkt der Messdatenanalyse mindestens ein Einzelereignis  $\text{EE}$  mit zugeordnetem Fahrzeug, welches in den Optimierungsprozessen untersucht wird.

Nach der Initialisierung sowie nach der Durchführung eines Zeitschritts wird für die Fahrzeuge aller  $\text{EE}$  des  $\text{GE}_{\text{stat}}$  geprüft, ob sie das Zeitintervall, welches zur Analyse von erfassten globalen Reaktionen betrachtet wird, bereits verlassen haben (Gleichung 3.7). Einzelereignisse, deren Fahrzeuge die Bedingung der Gleichung 3.7 erfüllen, gelten als

identifiziert und werden abgelegt. Die Einzelereignisse werden in den Optimierungsprozessen nicht weitergehend behandelt. Da die Fahrzeuge der Einzelereignisse möglicherweise die Ursache von Tragwerksreaktionen darstellen, die unter anderem die Messwerte eines aktuell betrachteten Zeitintervalls hervorriefen, werden die Einzelereignisse jedoch zunächst im statischen Gesamt ereignis beibehalten.

$$t_0 < t_{\text{glo,min}} \quad (3.7)$$

In einer anschließenden Prüfung werden die EE des  $GE_{\text{stat}}$  festgestellt, welche nicht mehr in den Optimierungsprozessen betrachtet werden und deren Fahrzeuge das Bauwerk verlassen haben. Diese Einzelereignisse üben keinen weiteren Einfluss auf die Fitnesswertermittlungen der evolutionären Optimierungsverfahren aus. Derartige EE sind für das  $GE_{\text{stat}}$  ohne Bedeutung und werden aus diesem entfernt.

Einzelereignisse, die weiterhin Bestandteil der Optimierungsprozesse sind, werden bezüglich des Erfordernisses der Ermittlung der Fahrzeugachseigenschaften überprüft. Die Attribute Auftretenszeitpunkt  $t_i$  und Last  $Q_i$  der  $i$ -ten Achse werden im Rahmen der Analyse von erfassten lokalen Tragwerksreaktionen bestimmt. Es werden hierzu die EE festgestellt, deren Fahrzeuge der Bedingung der Gleichung 3.8 nachkommen. Der Parameter  $a$  bezeichnet hierin eine Größe, welche die Anzahl der Zeitschritte bis zur erstmaligen Optimierung der Fahrzeugachseigenschaften bestimmt.

$$t_0 < t_{\text{glo,min}} + a \cdot \bar{t}_{\text{glo}} \quad \text{mit } 0,0 < a < 1,0 \quad (3.8)$$

Bei Erfüllung der Bedingung gemäß Gleichung 3.8 und zugleich noch nicht erfolgter Ermittlung der Achsattribute oder maßgeblich geänderter Fahrzeuggeschwindigkeit gegenüber den Ergebnissen des vorherigen Zeitschritts werden die erfassten lokalen Tragwerksreaktionen analysiert.

Basierend auf dem  $GE_{\text{stat}}$  und den zugeordneten EE werden schließlich die globalen Reaktionen untersucht. Im Rahmen dieser Analyse werden für alle EE, die Gegenstand der Optimierungsprozesse sind, übergeordnete Fahrzeugeigenschaften, wie der Auftretenszeitpunkt des Fahrzeugs  $t_0$ , das Gesamtgewicht  $Q_{\text{tot}}$  und die Geschwindigkeit  $v$ , ermittelt. Zudem werden mit Hilfe dieser Analyse mögliche Folgefahrzeuge identifiziert.

Sofern keine weiteren Messdaten vorhanden sind, endet die Messdatenanalyse. Andernfalls wird ein Zeitschritt ausgeführt und das nachfolgende Zeitintervall untersucht.



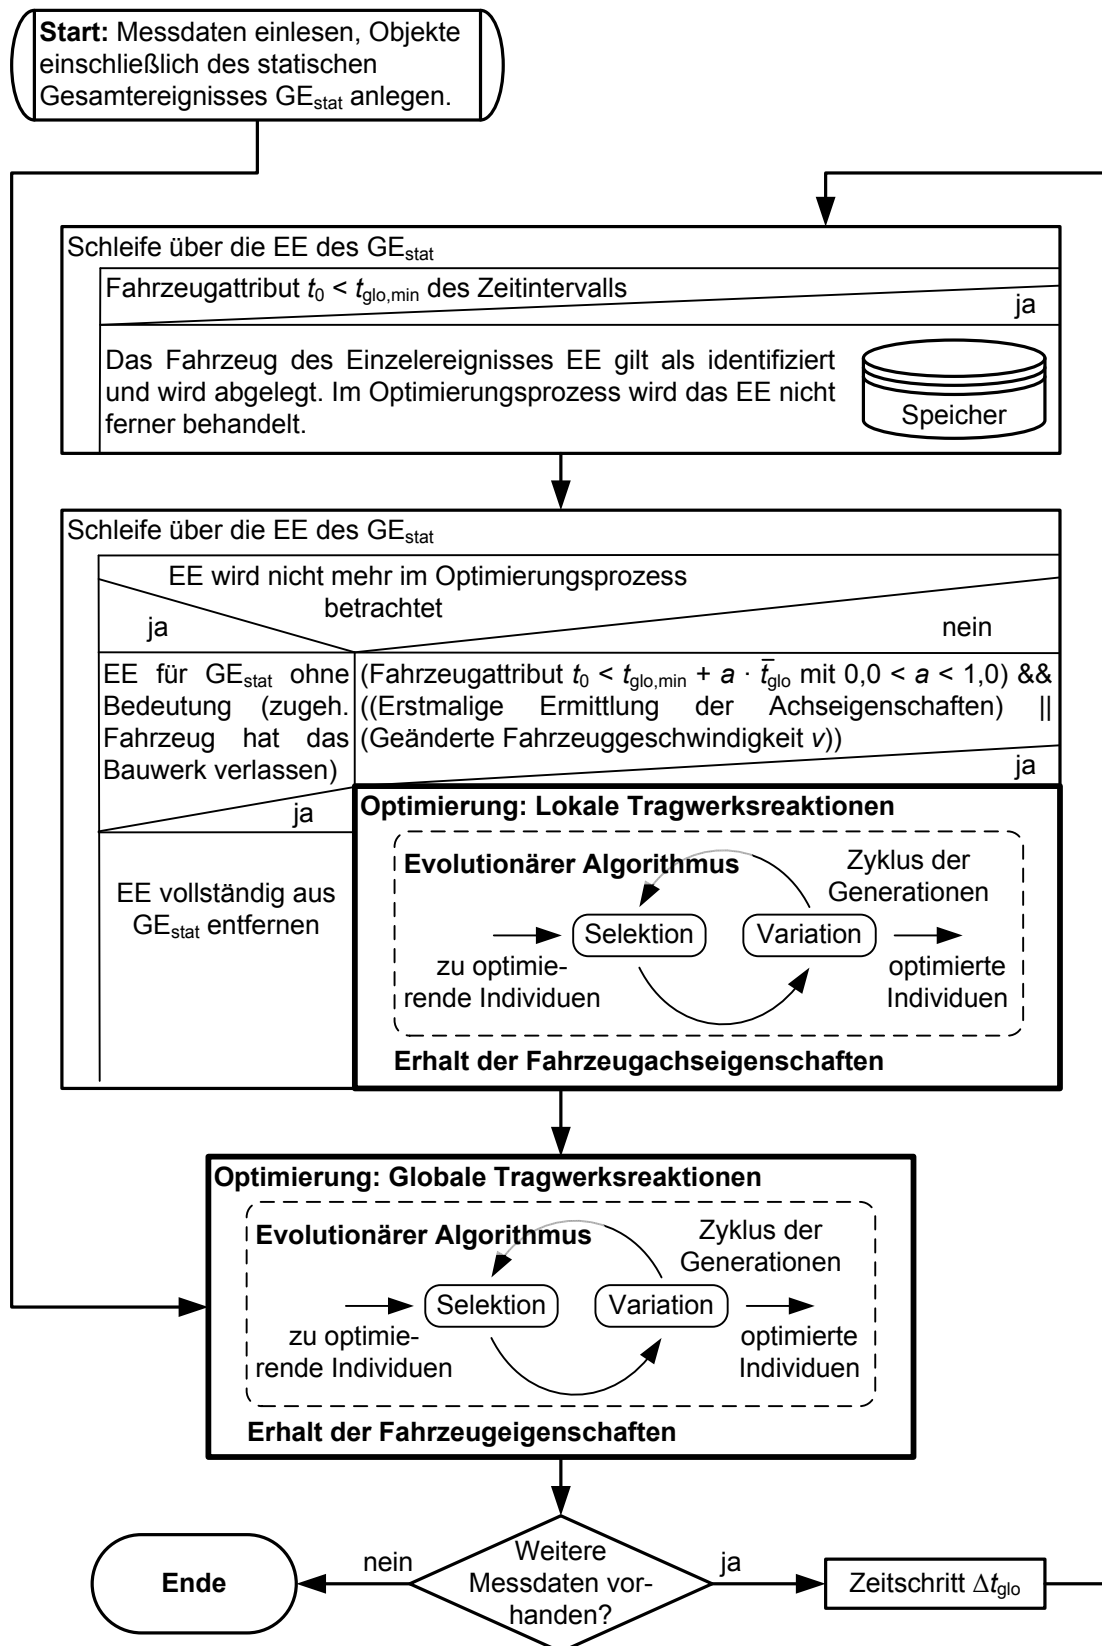


Abbildung 3.21: Struktogramme der Messdatenanalyse

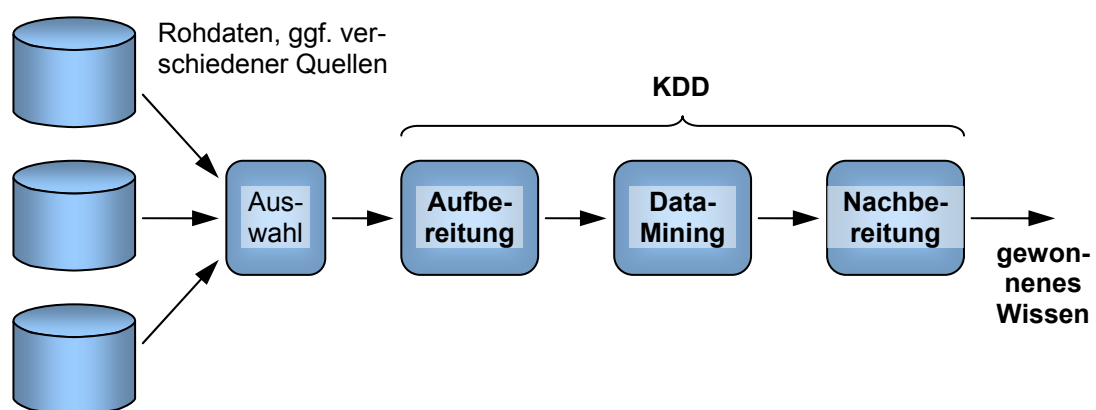


# Kapitel 4

## Implementierung

### 4.1 Übersicht, Voraussetzungen

Die Wissensentdeckung in Datenbanken (englisch: Knowledge Discovery in Databases, KDD) beschäftigt sich mit Methoden und Techniken zum Erhalt verwendbarer hochwertiger Informationen aus „voluminösen“, „rohen“ Datenbeständen. Der KDD-Prozess sieht in der Hauptsache drei konsequente Schritte vor: (i) Daten-Aufbereitung, (ii) Data-Mining und (iii) Daten-Nachbereitung [FrPM92, FaPS96, Mitr02] (Abbildung 4.1). Im Vorgehen stellt Data-Mining den wesentlichen Analyseschritt dar – es ist der eigentliche Kern, welcher zur Erkennung und Extraktion von Mustern und Regelmäßigkeiten dient. Um größtmöglichen Erfolg im Data-Mining zu haben, wird dieser Vorgang im Gesamtprozess durch eine Daten-Auf- und -Nachbereitung umrahmt.



**Abbildung 4.1:** Prozess der Wissensentdeckung in Datenbanken (KDD)

Die dargestellten drei Schritte des KDD-Prozesses gelten gleichermaßen im Rahmen der Lastidentifikation auf der Basis von kontinuierlich erfassten Tragwerksreaktionen.

Die Messdatenanalyse zur Feststellung einzelner Fahrzeuge einschließlich der beschreibenden Attribute kann bezogen auf die Abbildung 4.1 als der Data-Mining Schritt betrachtet werden. Die Daten-Aufbereitung beinhaltet die erforderlichen Methoden und Techniken, um die anschließende Analyse zu ermöglichen bzw. deren effizienten Ablauf zu unterstützen. Die Nachbereitung umfasst sämtliche Aspekte, welche die Interpretation und Verwendung der gewonnenen Informationen betreffen.

Um die Eignung des im vorangegangenen Kapitel vorgestellten Ansatzes zu demonstrieren, wurde dieser prototypisch implementiert. Mit Hilfe des umgesetzten IIM-Algorithmus wird im 5. Kapitel eine Evaluierung der angewandten Soft Computing Methoden durchgeführt. Im 6. Kapitel wird die entstandene Softwareapplikation zur Auswertung von Messdaten, die im Rahmen einer Dauermessung über 4 Monate an einem repräsentativen Brückenbauwerk gewonnen wurden, eingesetzt. Zur Vorhaltung und Aufbereitung der Messdaten wurde eine Softwareapplikation mit der Bezeichnung PreProc entwickelt und implementiert. Die Nachbereitung der erhaltenen Ergebnisse wird mit Hilfe einer entwickelten Anwendung namens PostProc und handelsüblichen Tabellenkalkulationsprogrammen durchgeführt. Die eigenen Entwicklungen wurden objektorientiert in der Programmiersprache C++ umgesetzt.

## 4.2 Daten-Vorhaltung und -Aufbereitung

Die entwickelte Softwareapplikation PreProc ermöglicht das Vorhalten von kontinuierlich erfassten Messdaten und bietet zugleich die erforderlichen Funktionalitäten zu deren Aufbereitung.

Die Abbildung 4.2 zeigt das Hauptfenster der entstandenen Anwendung. In der Ansicht sind 8 s Messaufzeichnung für 4 Messelemente vom 26.04.2006 von 11:12:42,6 Uhr bis 11:12:50,6 Uhr zu erkennen. Prinzipiell kann eine beliebige Anzahl an Messsignalen visualisiert werden.

Das Vorhalten der Messdaten erfolgt für einzelne Sensoren. Die Speicherung der Daten wird binär in einem eigens entwickelten Datenformat vorgenommen. Die Anwendung verfügt über Import-Funktionen, um digital erfasste Messgrößen einzulesen. Das entwickelte Datenformat berücksichtigt die speziellen Anforderungen hoher Datenvolumina, die im Rahmen von Dauermessungen anfallen. Ein einzelnes Messelement, welches mit 250 Hz abgetastet wird, hat in einer Woche 2,3 GByte Messdaten zur Folge ( $= 604800 \text{ s} \{1 \text{ Woche}\} \cdot 250 \text{ Hz} \cdot 16 \text{ Byte} \{2 \text{ double: Zeit- \& Messwert}\} / 1024^3$ ). Da derartige Volumina nicht als Ganzes im Hauptspeicher bearbeitet werden können, werden die

Messdaten in „Päckchen“ begrenzter Umfänge in einzelnen serialisierten Datendateien abgelegt (Datei-Erweiterung: dat) und verarbeitet. Der Datenstruktur der doppelt verknüpften Listen (englisch: doubly linked-lists) entsprechend verweisen die dat-Dateien auf die jeweils vorherige und folgende Datei. In der Listenstruktur referenzieren die erste Datendatei als vorherige Datei und die letzte als folgende auf Null. Zur Bearbeitung der Messdaten wird zu einem Zeitpunkt maximal eine Datendatei in den Hauptspeicher geladen. Mit Hilfe von geeigneten Methoden können einzelne Messwerte direkt angesprochen, Messzeiträume erhalten, bearbeitet und visualisiert werden. Um den gezielten Zugriff auf Messdaten eines Sensors zu ermöglichen, werden relative Dateipfade und Messzeiträume der Datendateien in einer separaten Verwaltungsdatei (Datei-Erweiterung: ver) vorgehalten. Zum Erhalt von Messdaten eines definierten Zeitpunkts oder Zeitraums muss hiermit nicht die gesamte Listenstruktur durchlaufen werden. Die Abbildung 4.3 verdeutlicht die entworfene Datenstruktur beispielhaft für Datendateien, welche jeweils 10 min Messungen enthalten. Für eine Abtastfrequenz von 250 Hz würde eine derartige dat-Datei eine Größe von etwa 2,3 MByte annehmen. Diese kann problemlos im Hauptspeicher verarbeitet werden.

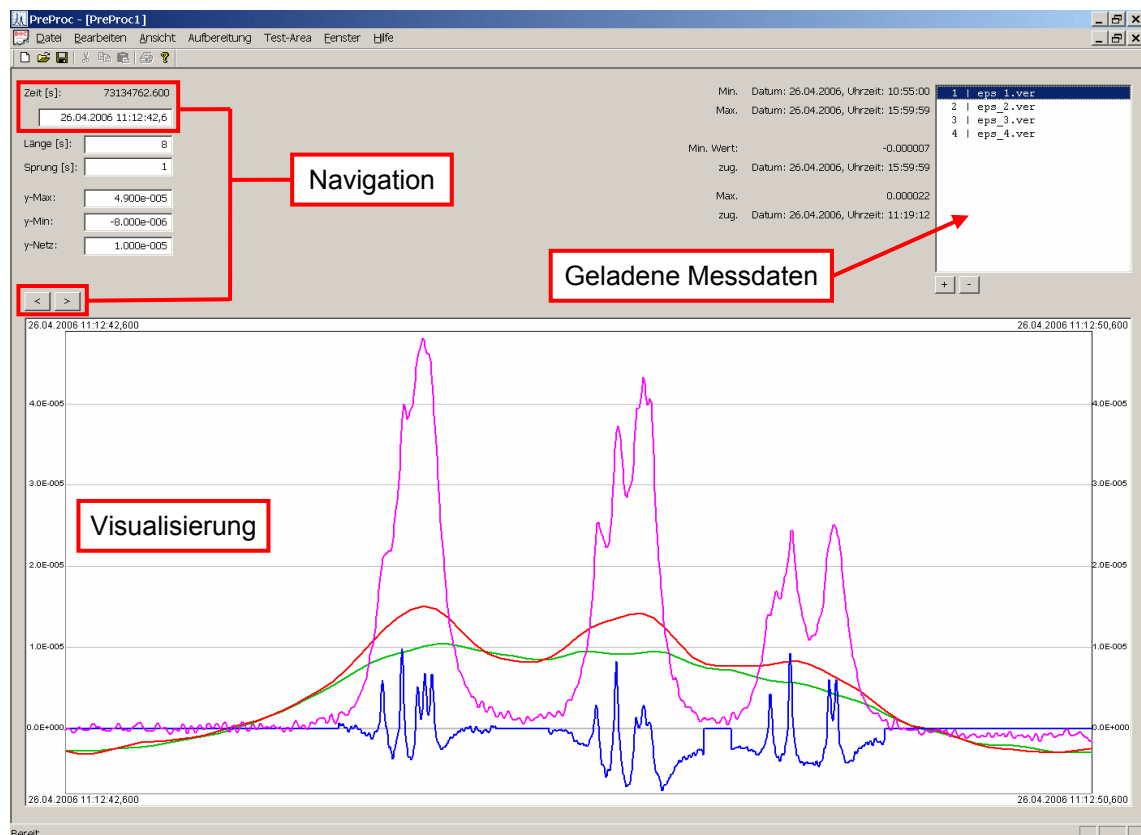


Abbildung 4.2: Entstandene Softwareapplikation PreProc


**Verwaltungsdatei (ver-Datei)**

→ enthält Zeiger auf die Messdaten

Bezeichnung: epsXX.ver
Datei 1: epsXX0001.dat Daten von 26.04.06 11:00:00 Uhr bis 26.04.06 11:10:00 Uhr
Datei 2: epsXX0002.dat Daten von 26.04.06 11:10:00 Uhr bis 26.04.06 11:20:00 Uhr
...

Direkter Zugriff mit Hilfe von  
Verweisen auf die dat-Dateien
**Datendateien (dat-Dateien)**

→ enthalten die Messdaten

**Abbildung 4.3:** Datenformat: Verwaltungsdatei und Datendateien eines Messsignals

Zur Aufbereitung von Messdaten enthält PreProc die folgenden Funktionalitäten, die über jeweils eigene Menüpunkte angesprochen werden:

- Nulllinienlage
- Synchronisation
- Skalierung
- Sampling
- Differenz
- Löschen
- Filtern

***Nulllinienlage***

Zur Unterstützung einer effizienten Messdatenanalyse im Rahmen des IIM-Algorithmus wird für die zu untersuchenden Messaufzeichnungen die Nulllinienlage ermittelt. Sensorsignale, welche in der kontinuierlichen Messdatenerfassung aus ihrem ursprünglichen Messniveau „abwandern“, erhalten hiermit ein definiertes Bezugsniveau. Der rechnerische Aufwand des Optimierungsprozesses wird erheblich reduziert, da das Messniveau nicht als Unbekannte behandelt werden muss.

Das Nullniveau wird berechnet durch die Feststellung von Zeitabschnitten ohne Fahrzeugverkehr auf dem Bauwerk. Gemäß Abbildung 4.4 werden im Zeitabstand  $m$  Abschnitte, deren Messwerte über die Dauer  $s$  Abweichungen kleiner oder gleich  $a$  zum

Mittelwert der Messwerte aufweisen, detektiert. Die Abschnitte werden als Stützpunkte zur Berechnung der Nulllinie herangezogen.




Abbildung 4.4: Nullniveau

Die Abbildung 4.5 zeigt den Dialog zur Berechnung der Nulllinienlage. Gemäß den vorherigen Erläuterungen sind Angaben bezüglich  $m$ ,  $s$  und  $a$  zu treffen.

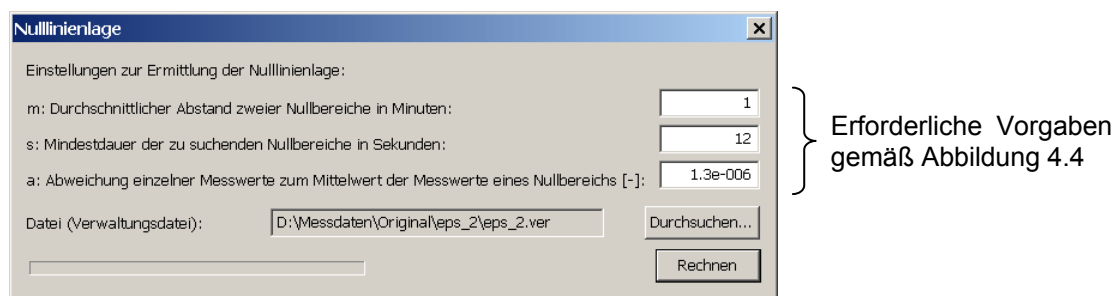


Abbildung 4.5: Dialog: Nullniveau

### Synchronisation

Diese Funktionalität ermöglicht das Verschieben einer Messaufzeichnung um einen zu definierenden Zeitwert. Die Aufzeichnungen verschiedener Messsensoren können hiermit synchronisiert werden.

### Skalierung

Unter Anwendung der Skalierung werden die Messwerte eines Sensorsignals mit einem fest vorzugebenden Faktor multipliziert. Mit Hilfe dieser Funktion können Längenänderungen  $\Delta l_m$ , die mit Wegaufnehmern über die Basislänge  $l$  gemessen wurden, in Dehnungen  $\Delta \varepsilon_m = \Delta l_m / l$  umgerechnet werden. Die Aufzeichnung von Dehnungsmessstreifen, die falsch gepolt wurden, kann durch Multiplikation mit  $-1$  hinsichtlich des Vorzeichens korrigiert werden.

### **Sampling**

Das Messsignal wird an eine zu definierende Abtastfrequenz angepasst. Die Wahl einer geringeren als die ursprüngliche Abtastfrequenz reduziert den Datenumfang bei Verlusten hinsichtlich der Auflösung des Messsignals.

### **Differenz**

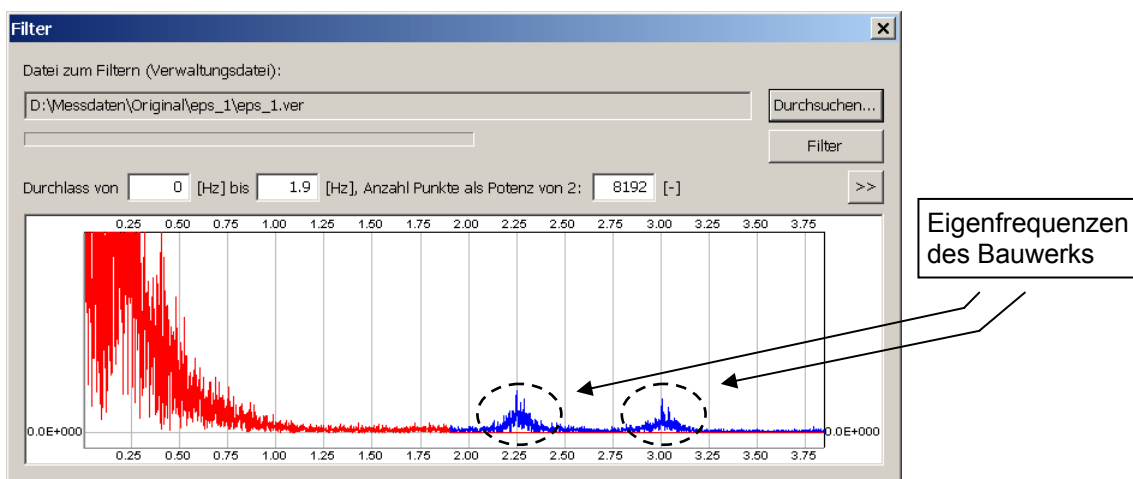
Zwei Messsignale werden voneinander subtrahiert. Zur Subtraktion können für die Signale jeweils Angaben bezüglich Synchronisation und Skalierung getroffen werden.

### **Löschen**

Diese Funktionalität erlaubt das Entfernen zu definierender Messabschnitte. Zu löschende Messabschnitte werden durch die Angabe der Zeitwerte „Beginn“ und „Ende“ beschrieben.

### **Filtern**

Zur Reduzierung von Signalrauschen und dynamischen Effekten wurde ein digitales Filter gemäß [Smit99] implementiert. Das Filter beruht auf einer Fast Fourier Transformation und ermöglicht das Entfernen gegebener Frequenzbereiche. Die Abbildung 4.6 zeigt den Dialog des Filters. Für die verwendeten Messdaten eines realen Bauwerks sind die Eigenfrequenzen, die auch im Rahmen von verifizierenden Finite Elemente Berechnungen festgestellt wurden, markiert.



**Abbildung 4.6:** Dialog: Digitales Filter

Zur Weiterverarbeitung von Messdaten bietet PreProc verschiedenste Export-Funktionen. Diese umfassen unter anderem den Export der Daten im csv-Format (zur



Verwendung in Tabellenkalkulationsprogrammen) und im Textformat mit Leerzeichen- oder Tabulatortrennung wahlweise mit Punkt oder Komma als Dezimaltrenner.

### 4.3 Messdatenanalyse

Der IIM-Algorithmus wurde prototypisch implementiert. Die entwickelte Softwareapplikation kann zur Analyse von Tragwerksreaktionen, die an einem Überbau mit einer Richtungsfahrbahn und zwei Fahrstreifen erfasst werden, eingesetzt werden. Zur Aufzeichnung von Tragwerksreaktionen, die vornehmlich durch globale oder lokale Anteile dominiert werden, sollte der Überbau einen Plattenbalken- oder Hohlkastenquerschnitt aufweisen. Der Schwerverkehr eines Fahrstreifens wird durch die Auswertung von zwei Sensorsignalen identifiziert. Die globalen Reaktionen werden hierzu mit Hilfe eines Sensors am Steg und die lokalen Reaktionen mit einem Sensor an der Unterseite der Fahrbahnplatte erfasst. Die Dehnungsberechnung erfolgt im implementierten Algorithmus durch die Auswertung von berechneten Einflusslinien (globale Stegreaktionen) und -flächen (lokale Plattenreaktionen). Die Abbildung 4.7 zeigt die Softwareapplikation.

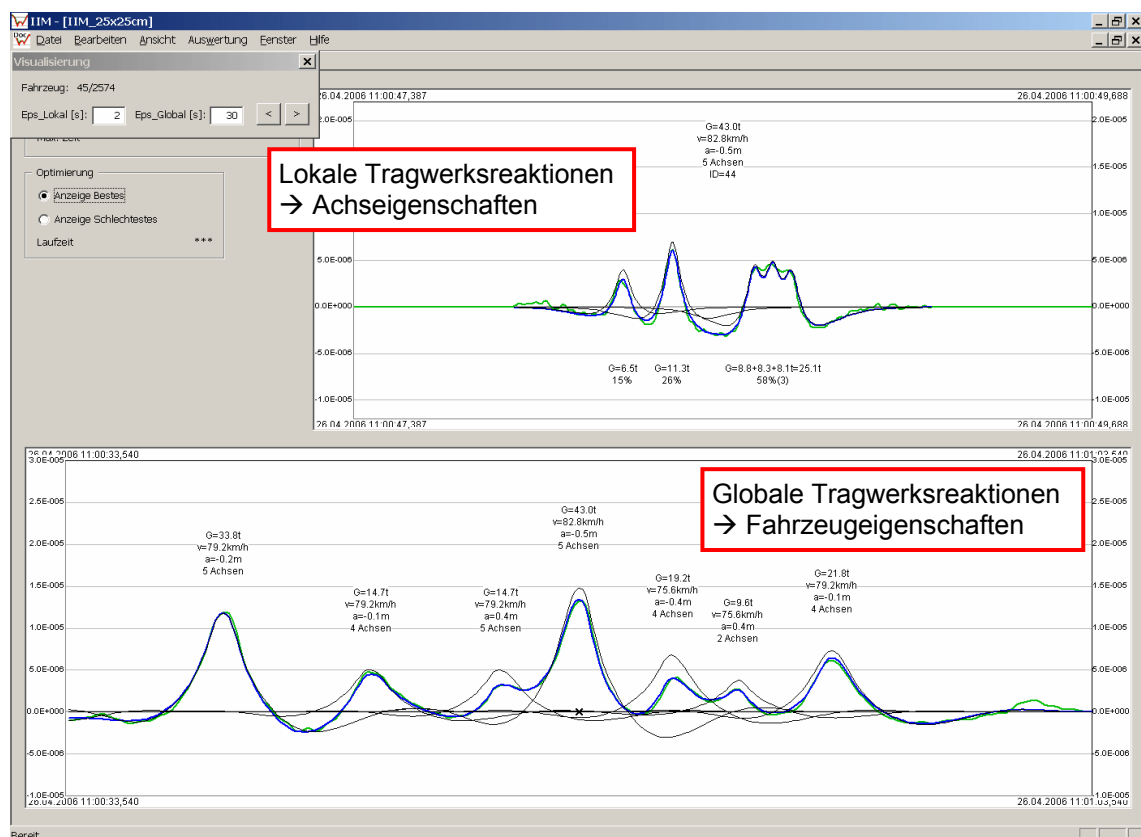


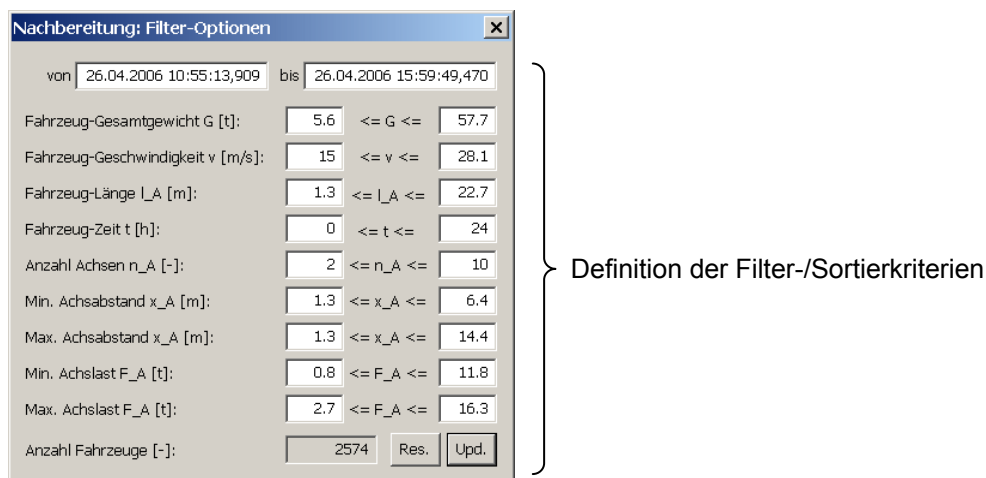
Abbildung 4.7: Screenshot der Softwareapplikation IIM

In den beiden Ansichten der IIM-Applikation gemäß Abbildung 4.7 sind sowohl die erfassten als auch die berechneten Tragwerksreaktionen dargestellt. Der unteren Ansicht können die globalen Reaktionen einschließlich der ermittelten Fahrzeuggesamtwichte und -geschwindigkeiten entnommen werden. Für das mit einem Kreuz markierte Fahrzeug werden in der oberen Ansicht die lokalen Reaktionen mit den ermittelten Achslasten gezeigt. Für dieses 5-achsige Fahrzeug wurden das Gesamtgewicht zu 43,0 t, die Geschwindigkeit zu 82,8 km/h und die Achslasten zu 6,5 t, 11,3 t, 8,8 t, 8,3 t und 8,1 t bestimmt. Die Ergebnisse stammen aus der Anwendung der Applikation im Rahmen einer Langzeitmessung an einem repräsentativen Brückenbauwerk (vgl. Kapitel 6).

Die Messdatenanalyse greift auf das entwickelte und in der PreProc-Applikation verwendete binäre Datenformat der Messdaten zurück. Die bereits vorhandenen Methoden zur Verarbeitung der Daten wurden somit direkt verwendet. Identifizierte Fahrzeugdaten werden binär abgespeichert.

## 4.4 Daten-Nachbereitung

Die entwickelte Softwareapplikation PostProc unterstützt die Evaluation und Interpretation der gewonnenen Ergebnisse. Die mit Hilfe der IIM-Applikation identifizierten und binär gespeicherten Fahrzeugdaten können eingelesen und die Ergebnisse zur weiteren Nachbereitung in Tabellenkalkulationsprogramme exportiert werden. Die Abbildung 4.8 zeigt den wesentlichen Dialog, der die Definition von Sortier- und Filterkriterien gestattet. Gemäß den getroffenen Vorgaben werden die Fahrzeuge nach Auswahl eines gesonderten Menüpunkts exportiert. Mögliche Ergebnisse der Nachbereitung in Tabellenkalkulationsprogrammen können dem Kapitel 6 entnommen werden.



**Abbildung 4.8:** Dialog: Einstellungen zur Nachbereitung gewonnener Ergebnisse

# Kapitel 5

## Evaluierung

### 5.1 Grundlagen

Zusätzlich zu einem adäquaten Entwurf sind der Prozess der Lösungsfindung sowie die erzielbare Lösungsqualität bei angewandten Methoden des Soft Computing von einer Vielzahl an Parametern abhängig. Ein günstiges Lösungsverhalten wird maßgeblich durch die zweckmäßige Wahl der wesentlichen Größen beeinflusst. Zur effizienten Lastidentifikation auf der Basis von Evolutionären Algorithmen und Neuronalen Netzen ist daher die detaillierte Untersuchung der entwickelten Verfahren erforderlich.

Im Rahmen von umfangreichen Studien werden die wichtigsten Parameter hinsichtlich ihres Einflusses auf das Lösungsverhalten evaluiert. Da angewandte Soft Computing Methoden stets im Umfeld der zu Grunde liegenden Problemstellung zu betrachten sind, wird die Evaluierung der eigenen Entwicklungen anhand eines Anwendungsproblems durchgeführt. Den Studien werden reale Messungen eines repräsentativen Brückenbauwerks zu Grunde gelegt (vgl. auch Kapitel 6).

Die Untersuchungen erfolgen losgelöst vom Gesamtansatz für die eingesetzten Neuronalen Netze und die entwickelten evolutionären Optimierungskerne zur Auswertung von erfassten globalen und lokalen Tragwerksreaktionen. Im Folgenden werden die prinzipiellen Vorgehensweisen der Evaluierung erläutert und im Anschluss die Ergebnisse der durchgeführten Studien gezeigt.

#### *Achsdetektion mit Hilfe künstlicher Neuronaler Netze*

Die Messdatenanalyse von erfassten lokalen Tragwerksreaktionen erfolgt statisch für vorgegebene Zeitbereiche (vgl. Kapitel 3.5). Zur Unterstützung eines effizienten Vorgehens wird im Rahmen des umgesetzten Optimierungsalgorithmus ein mehrschichtiges

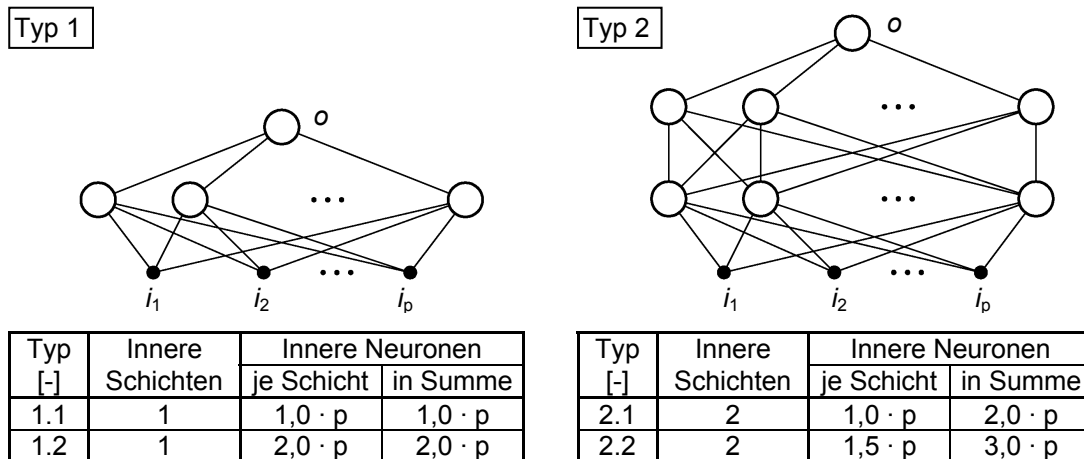
vollverknüpftes vorwärtsbetriebenes Neuronales Netz (NN) eingesetzt. Mit Hilfe des Neuronalen Netzes werden die Auftretenszeitpunkte  $t_i$  der Achsen ( $i$ : Index der Achse) eines Fahrzeugs vor Ablauf der Optimierungsroutine abgeschätzt.

Im Unterschied zu evolutionären Optimierungsverfahren existieren bei Neuronalen Netzen keine manuell, vorab zu definierenden Parameter, welche den Ablauf der NN-Auswertung direkt beeinflussen. Das NN-Lösungsverhalten wird im Wesentlichen durch Netzstruktur und Trainingsumfang bestimmt. Die Evaluierung erfolgt daher für:

- Netze unterschiedlicher Anzahl von Eingängen,
- Netze unterschiedlicher Topologien und
- Netze unterschiedlichen Trainingsumfangs.

Die minimal erforderliche Anzahl der Eingänge  $p$  folgt aus der Überlegung, wie viele aufgezeichnete, diskrete Messpunkte zur eindeutigen Darstellung des extremalen Messergebnisses infolge von mindestens einer Achslast erforderlich sind. Der  $k$ -te diskrete Messpunkt wird beschrieben durch einen Messzeitpunkt  $t_{in,k}$  und -wert  $\Delta\epsilon_{m,in,k}$ . Zur NN-Auswertung werden ohne Berücksichtigung von  $t_{in,k}$  normierte Werte  $\|\Delta\epsilon_{m,in,k}\|$  an das NN angelegt (vgl. auch Gleichung 3.3). Bei einer konstanten Abtastfrequenz ist der Bezug auf  $t_{in,k}$  zur NN-Analyse nicht notwendig. Die Anzahl der erforderlichen Eingänge ist daher von der Abtastfrequenz  $f_s$  des Messsignals abhängig. Die im Rahmen der Evaluierung betrachteten lokalen Tragwerksreaktionen des Anwendungsproblems wurden mit 250 Hz abgetastet. Für  $f_s = 250$  Hz, einen minimalen Achsabstand von  $x_{min} = 1,31$  m (üblicher Achsabstand der Tripelachse von Sattelauflegern) und eine angenommene maximale Fahrzeuggeschwindigkeit von  $v_{max} = 30$  m/s sind mindestens 11 Eingänge ( $= 250 \cdot 1,31 / 30$ ) erforderlich, um eine Achse in der Messung abzubilden. In der Evaluierung werden Netze mit 20, 40 und 50 Eingängen betrachtet.

Der NN-Inferenzmechanismus wird in besonderem Maße durch die gewählte Netzstruktur bestimmt. Aufgrund des Black-Box-Charakters von Neuronalen Netzen kann der Ablauf der Auswertung nur mit Schwierigkeiten direkt interpretiert werden. Aus diesem Grund werden in den Studien die 4 Topologie-Typen gemäß den Festlegungen der Abbildung 5.1 gegeneinander bewertet. Hierbei kennzeichnet der Typ 1 Netze mit einer inneren Schicht, wohingegen Typ 2 insgesamt zwei verdeckte Schichten berücksichtigt. Es wird eine Anzahl innerer Neuronen von 1,0-mal der Anzahl Eingänge  $p$  bis  $3,0 \cdot p$  betrachtet. Die Varianten 1.2 und 2.1 weisen mit  $2,0 \cdot p$  eine identische Anzahl innerer Neuronen bei unterschiedlicher Anzahl von verdeckten Schichten auf.



**Abbildung 5.1:** Untersuchte Topologien

Der Trainingsumfang der betrachteten Neuronalen Netze wird in der Evaluierung variiert. Insbesondere der Anteil der positiven zu den negativen Datensätzen wird bei konstanter Anzahl an Durchläufen und gleichen Genauigkeitsanforderungen verändert. Ein positiver Trainingsdatensatz beschreibt im Unterschied zu einem negativen für  $t_{in,mid}$  (vgl. Gleichung 3.5) die Anwesenheit einer Achse. Der Ausgabewert eines positiven Datensatzes wird zu 1 gesetzt, der eines negativen zu 0. Die Berücksichtigung unterschiedlicher Verhältnisse der positiven zu den negativen Datensätzen dient zur Bewertung eines möglichen Übertrainings bzw. der Übergeneralisierung der Netzwerke hinsichtlich eines speziellen Typs der Trainingsdatensätze. Es werden Kombinationen aus 2000 positiven zu 1000, 2000 und 4000 negativen Datensätzen untersucht.

Zur NN-Evaluierung werden Testdatensätze verwendet, die nicht zum Training herangezogen wurden. Grundsätzlich wird die Verifizierung eines entwickelten Verfahrens anhand von Daten durchgeführt, die nicht zur Kalibrierung dienen. Sowohl die Trainings- als auch die Testdatensätze wurden auf der Basis von je einer Stunde Messdatenaufzeichnung erstellt. Die Trainingsdatensätze basieren auf Bauwerksmessungen vom 26.04.2006 (regulärer Werktag) in der Zeit von 10:55:13 Uhr bis 12:02:24 Uhr und weisen insgesamt 626 Zeitbereiche mit 2737 markierten Achsen auf. Die Testdatensätze beruhen auf Messungen des gleichen Tags in der Zeit von 13:00:26 Uhr bis 13:59:58 Uhr und enthalten insgesamt 500 Zeitbereiche bei 2107 markierten Achsen. Die Anzahl der Testdatensätze ist von der Anzahl der NN-Eingänge abhängig: Der Evaluierung der Netze mit 20 Eingängen liegen 134650, jenen mit 40 Eingängen 124650 und den Systemen mit 50 Eingängen 119651 Testdatensätze zu Grunde. Die Messungen wurden jeweils mit Videoaufzeichnung begleitet, so dass den gewonnenen Messdaten sämtliche die Brücke überfahrenden Fahrzeuge zugeordnet werden konnten.

### ***Evolutionäre Optimierungskerne zur Analyse erfasster Tragwerksreaktionen***

Den Kern der Messdatenanalyse zur Lastidentifikation bilden zwei evolutionäre Optimierungsverfahren zur Auswertung von erfassten globalen und lokalen Tragwerksreaktionen. Die beiden entwickelten Verfahren unterscheiden sich im Detail und werden getrennt untersucht. Der effiziente Ablauf bei minimiertem Rechenaufwand sowie die erzielbare Lösungsqualität der entwickelten Optimierungsalgorithmen werden durch eine Vielzahl an Größen bestimmt. Von hoher Bedeutung sind die Parameter:

- Populationsgröße über Generationen,
- Rekombinations- und
- Mutationswahrscheinlichkeiten.

Voruntersuchungen anhand verschiedener Problemstellungen [PSFA03, SFAP04, LSFB06, PuSL07] haben gezeigt, dass ein effizienter Optimierungsprozess maßgeblich durch die folgende Parameterwahl unterstützt wird:

- Initialisierung und Durchlauf erster Generationen – Exploration: Zur umfassenden Suche im Lösungsraum bei hoher Diversität hat sich die Verwendung einer vergleichsweise großen Population, deren Individuen einer erhöhten Rekombination und geringer Mutation ausgesetzt werden, als sinnvoll erwiesen.
- Durchlauf späterer Generationen – Exploitation: Die Betrachtung einer deutlich verringerten Anzahl von Individuen, die bereits sehr gute Lösungen repräsentieren, bei verminderter Rekombination und erhöhter Mutation ermöglicht die abschließende Feinabstimmung der Lösungskandidaten.

Zur Berücksichtigung des beobachteten günstigen Lösungsverhaltens wird im Rahmen der beiden umgesetzten evolutionären Optimierungsverfahren eine deterministische Parameteradaption entsprechend der allgemeinen Darstellung der Abbildung 5.2 durchgeführt. Zur Anpassung der evolutionären Parameter wird eine Unterscheidung nach Abschnitt 1, Übergangsbereich und Abschnitt 2 vorgenommen. In der Tabelle 5.1 werden die wesentlichen Notationen angegeben.

Im Vergleich zu herkömmlichen Verfahren erfordern Evolutionäre Algorithmen, deren Parameter im Optimierungsprozess deterministisch angepasst werden, die Angabe zusätzlicher Kennwerte. Die Anzahl zu definierender Größen erhöht sich hierdurch maßgeblich bei einem deutlichen Gewinn an Flexibilität des Algorithmus [EiHM99].

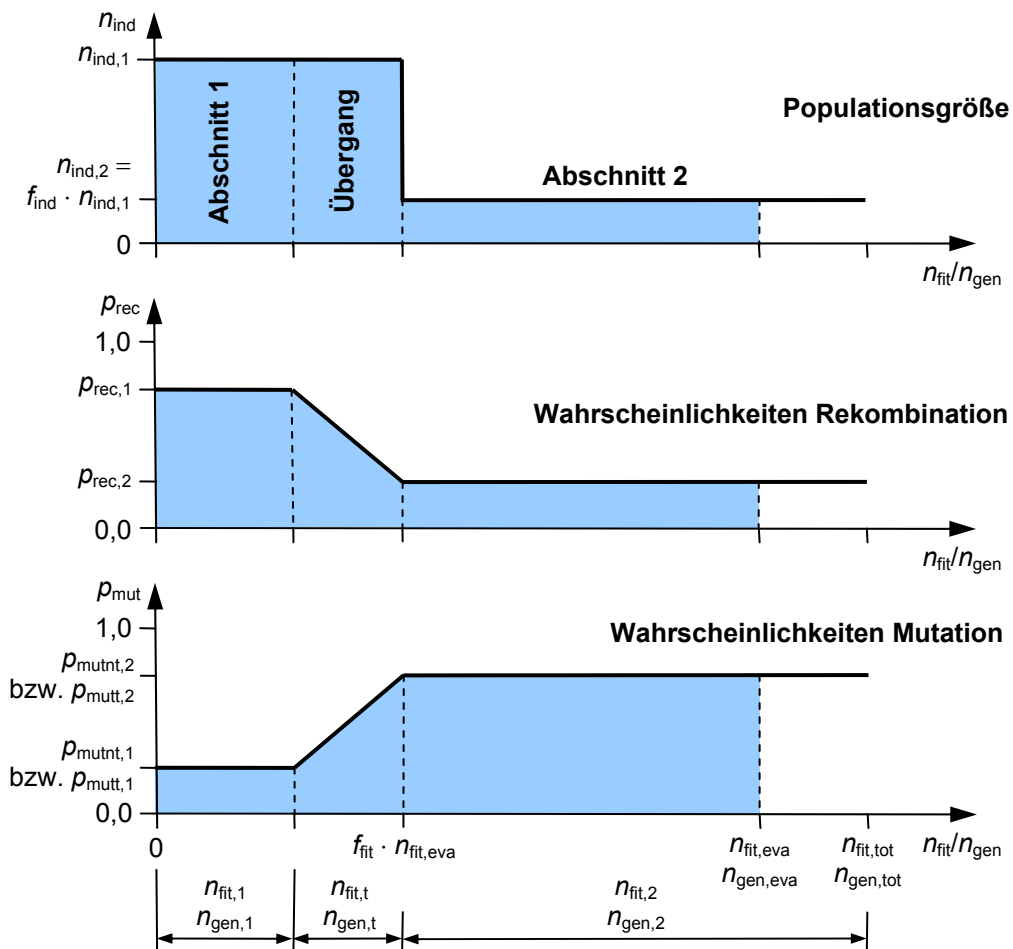


Abbildung 5.2: Parameteradaption


Tabelle 5.1: Notationen

i	Index des Abschnitts im Optimierungsprozess: 1, t (Übergang) oder 2
eva	Index des Evaluierungspunktes
tot	Index der Gesamtanzahl
$n_{\text{fit}}$	Anzahl der Fitnesswertermittlungen
$n_{\text{gen}}$	Anzahl der Generationen
$n_{\text{ind}}$	Anzahl der Individuen der Population
$n_{\text{sel}}$	Selektionspotenz
$n_{\text{eli}}$	Anzahl der Individuen, die per Elitismus übertragen werden
$n_{\text{rec}}$	Anzahl der Rekombinationen zur Bildung eines Nachkommens aus zwei Eltern
$n_{\text{mut}}$	Anzahl der Mutationen eines Nachkommens
$p_{\text{rec}}$	Wahrscheinlichkeit der Rekombination
$p_{\text{mut}}$	Wahrscheinlichkeit der Mutation, allgemein
$p_{\text{mutnt}}$	Wahrscheinlichkeit der Mutation nicht-terminierter Symbole
$p_{\text{mutt}}$	Wahrscheinlichkeit der Mutation terminierter Symbole
$f_{\text{ind}}$	Faktor der Anzahl an Individuen
$f_{\text{fit}}$	Faktor der Anzahl an Fitnesswertberechnungen

Die Untersuchungen zu den evolutionären Optimierungsverfahren werden anhand von definierten Parametersätzen vorgenommen. Die Parametersätze berücksichtigen Kombinationen der Einflussgrößen gemäß Abbildung 5.2, die kennzeichnend das Lösungsverhalten, die erzielbare Lösungsgüte und den Rechenaufwand der jeweiligen Optimierungsaufgabe bestimmen. Aufgrund der stochastischen Lösungssuche von Evolutionären Algorithmen werden in Anlehnung an [HeLV98] je Parametersatz 50 Experimente durchgeführt.

Die Evaluierung erfolgt auf Basis der erhaltenen Fitnesswertentwicklungen (vgl. hierzu auch die Gleichungen 3.2 und 3.6) der Experimente. Die Abbildung 5.3 zeigt schematisch eine Fitnesswertentwicklung einschließlich der Bewertungskriterien der Evaluierung, welche nachfolgend detailliert eingeführt werden. Da Minimierungsprobleme vorliegen, wird zunächst die Entwicklung der minimalen Fitness  $e_{\text{fit,min}}$  betrachtet. Der Fortschritt der Fitness der schlechtesten Individuen  $e_{\text{fit,max}}$  und der durchschnittlichen Fitness der Population  $e_{\text{fit,avg}}$  werden in Detailuntersuchungen berücksichtigt. Sofern die Verwendung der Bezeichnung  $e_{\text{fit,min}}$  nicht aus Gründen der Eindeutigkeit erforderlich ist, wird nachfolgend  $e_{\text{fit}}$  notiert.

Zur Bewertung von unterschiedlichen Parametersätzen werden die Ergebnisse zu einer fixen Anzahl an Fitnesswertberechnungen  $n_{\text{fit,eva}}$  betrachtet. Die Berücksichtigung einer Anzahl durchgeführter Fitnesswertberechnungen – statt einer Anzahl durchlaufener Generationen – gewährleistet, dass den Untersuchungen ein jeweils identischer Rechenaufwand zu Grunde liegt. Die Ergebnisse einer evolutionären Optimierung können hierdurch direkt miteinander verglichen werden. Die Anzahl an Berechnungen  $n_{\text{fit,eva}}$  wird je Optimierungskern derart gewählt, dass für einzelne Parametersätze gute – wenn nicht sogar die globalen – Problemlösungen gefunden werden.



**Abbildung 5.3:** Kriterien zur Beurteilung der Fitnesswertentwicklung



Die Anzahl der Fitnesswertberechnungen  $n_{\text{fit}}$  in Abhängigkeit von der Anzahl durchlaufener Generationen  $n_{\text{gen}}$  ergibt sich gemäß den Gleichungen 5.1 und 5.2. In die Bestimmung der Größe  $n_{\text{fit}}$  gehen zusätzlich zum Wert  $n_{\text{gen}}$  die Anzahl betrachteter Individuen ( $n_{\text{ind},1}$  und  $n_{\text{ind},2}$ ) und die Anzahl der Individuen, welche per Elitismus ( $n_{\text{eli},1}$  und  $n_{\text{eli},2}$ ) in die Nachfolgegeneration übertragen werden, ein. Eine Fallunterscheidung ist erforderlich, da die Verläufe der Parameteradaption abschnittsweise definiert vorliegen.

für  $n_{\text{gen}} \leq n_{\text{gen},1} + n_{\text{gen},t}$  :

$$n_{\text{fit}} = (n_{\text{ind},1} - n_{\text{eli},1}) \cdot n_{\text{gen}} + n_{\text{ind},1} \quad (\text{additiver Term aus der Initialisierung}) \quad (5.1)$$

sonst:

$$n_{\text{fit}} = (n_{\text{ind},1} - n_{\text{eli},1}) \cdot (n_{\text{gen},1} + n_{\text{gen},t}) + (n_{\text{ind},2} - n_{\text{eli},2}) \cdot (n_{\text{gen}} - (n_{\text{gen},1} + n_{\text{gen},t})) + n_{\text{ind},1} \quad (5.2)$$

Zur Initialisierung ( $n_{\text{gen}} = 0$ ) findet eine Fitnesswertermittlung für alle Individuen statt. Dementsprechend beginnt der Verlauf einer Fitnesswertentwicklung nicht bei  $n_{\text{fit}} = 0$ , sondern bei  $n_{\text{fit}} = n_{\text{ind},1}$  (vgl. auch Abbildung 5.3 und Gleichung 5.1).

Untersuchungen zum Einfluss der Populationsgrößenentwicklung über die Generationen und der zweckmäßigen Wahl der Lage des Übergangsbereichs werden mit Hilfe der Beziehungen der Gleichungen 5.3 und 5.4 vorgenommen.

$$f_{\text{ind}} = n_{\text{ind},2} / n_{\text{ind},1} \quad (5.3)$$

$$f_{\text{fit}} = [n_{\text{fit},1} + n_{\text{fit},t}] / n_{\text{fit,eva}} \quad (5.4)$$

Der Wert  $f_{\text{ind}}$  stellt den Quotienten aus der Anzahl der Individuen  $n_{\text{ind},2}$  und  $n_{\text{ind},1}$  dar. Aufgrund der Unterscheidung von Abschnitten in der Parameteradaption kennzeichnet dieser Wert indirekt die Entwicklung der Populationsgröße über die Generationen.

Der Wert  $f_{\text{fit}}$  beschreibt mit Bezug auf  $n_{\text{fit,eva}}$  die Summe der Anzahl an Fitnesswertberechnungen des Abschnitts 1 und des Übergangsbereichs. Diese Größe lässt demnach erkennen, nach welchem Anteil von  $n_{\text{fit,eva}}$  Fitnesswertberechnungen die Parametereinstellungen des Abschnitts 2 erreicht werden.

Für  $f_{\text{ind}}$  werden Werte kleiner 1,0 definiert, da dies den geschilderten Beobachtungen zum Lösungsverhalten der bereits umgesetzten Evolutionären Algorithmen entspricht. Der Ausdruck  $f_{\text{fit}}$  wird variiert, da hierfür keine Erfahrungen vorliegen.

Die Untersuchungen zu den Rekombinations- und Mutationswahrscheinlichkeiten der Algorithmen erfolgen ebenfalls in Anlehnung an die dargelegten Erkenntnisse der Voruntersuchungen. Im Abschnitt 1 wird eine vergleichsweise hohe Rekombinations- bei geringer Mutationswahrscheinlichkeit getestet. Für den Abschnitt 2 werden dementsprechend gegenläufige Einstellungen geprüft.

Die Bewertung der Optimierungsverfahren erfolgt primär für die erzielte Lösungsgüte der Parametersätze bzw. deren Experimente. Hierzu wird der Fitnesswert  $e_{\text{fit,eva}}$  nach  $n_{\text{fit,eva}}$  Fitnesswertberechnungen herangezogen. Geringe Fitnesswerte kennzeichnen gute Lösungen der Problemstellung.

Als sekundäres Bewertungskriterium wird der Flächeninhalt  $A_{\text{fit,eva}}$  der Fitnesswertentwicklung bis  $n_{\text{fit,eva}}$  Berechnungen verwendet. Mit Hilfe dieses Werts wird der effiziente Ablauf eines evolutionären Optimierungsprozesses beurteilt. Ein geringer Wert deutet auf eine hohe Konvergenzgeschwindigkeit hin.


Zur Evaluierung werden die folgenden evolutionären Parameter als Konstanten behandelt:  $n_{\text{eli}} = 2$ ,  $n_{\text{sel}} = 2$ ,  $n_{\text{rec}} = 1$  und  $n_{\text{mut}} = 1$ .

## 5.2 Achsdetektion mit Hilfe künstlicher Neuronaler Netze

Die Evaluierung der entwickelten Neuronalen Netze hinsichtlich ihres Lösungsverhaltens wird zweistufig durchgeführt. Im ersten Schritt werden unterschiedliche Netze bei jeweils gleichem Topologie-Typ (vgl. Abbildung 5.1) für die Testdatensätze über die Anteile der richtig bzw. falsch detektierten Achsen bewertet. Im Anschluss werden Untersuchungen zur Bedeutung der NN-Topologie an Netzen mit einer fixen Anzahl von Eingängen und identischem Training durchgeführt.

Die Anwendung der entwickelten NN auf reale Messdaten führt auf Ausgänge  $o$  zwischen 0,0 und 1,0. Eine Achse gilt in den Messdaten als detektiert, wenn für einen Satz Eingänge der Ausgang  $o$  den Grenzwert  $o_{\text{ident}}$  (vgl. Gleichung 3.4) übertrifft. Zur Evaluierung der NN-Ausgänge sowie zur Definition des Werts  $o_{\text{ident}}$  wird der zeitliche Abstand  $t_{\text{dis}}$  der Messung des Zeitpunkts  $t_{\text{in,mid}}$  (vgl. Gleichung 3.5) zum Auftretenszeitpunkt der nächstgelegenen, markierten Achse der Testdatensätze herangezogen. Die Abbildung 5.4 zeigt die Definition von  $t_{\text{dis}}$  beispielhaft anhand der Messung zur Überfahrt eines 3-achsigen Lastkraftwagens vom 26.04.2006 um 14:46:02 Uhr. Durch die Zuordnung von Abschnitten der Messaufzeichnung zu den einzelnen Achsen können die Ergebniswerte  $o$  der NN-Analyse direkt den Achsen zugewiesen werden.

Messwerte, die zur Achsdetektion an das NN angelegt werden, vgl. auch Abbildung 3.14




**Abbildung 5.4:** Definition der Größe  $t_{\text{dis}}$

Das Vorgehen zur Bestimmung von NN-Kriterien, welche evaluiert werden, wird nachfolgend mit Hilfe eines NN des Topologie-Typs 2.1 (2 verdeckte Schichten mit jeweils  $p$  Neuronen) mit 50 Eingängen, das auf 2000 positive und 2000 negative Datensätze trainiert wurde, dargelegt. Dieses Netz hat in den Untersuchungen sehr gute Ergebnisse erzielt und weist Charakteristika auf, die für sämtliche untersuchten Netze gelten. Zur Erläuterung eignet sich dieses Neuronale Netz daher gut.

Die Abbildung 5.5 gibt für die vorliegenden 119651 Testdatensätze die Häufigkeit der Ausgänge  $o$  in Abhängigkeit vom zeitlichen Abstand  $t_{\text{dis}}$  wieder. Es ist zu erkennen, dass die Häufigkeiten für negative und positive  $t_{\text{dis}}$  einer Symmetrie unterliegen. Das zu  $t_{\text{dis}} = 0$  symmetrische Auftreten der Ausgänge  $o$  wurde für alle untersuchten Neuronalen Netze beobachtet. Im Zusammenhang mit Ausgängen  $o$  können daher zur Evaluierung Beträge von  $t_{\text{dis}}$  betrachtet werden. Darüber hinaus ist festzustellen, dass das NN für Messpunkte in der Nähe einer tatsächlich vorhandenen Achse häufig Werte zwischen 0,95 und 1,0 ausgibt, wohingegen für größere Abstände zur markierten Achse vorwiegend Ausgänge zwischen 0,0 und 0,05 erhalten werden.


Zur Evaluierung der unterschiedlichen Neuronalen Netze wird eine Achsdetektion bis zu einer Distanz  $|t_{\text{dis}}| \leq 0,016$  s als korrekt akzeptiert. Achsen, welche mit einem Abstand  $|t_{\text{dis}}| > 0,016$  s festgestellt werden, werden als fälschlicherweise detektiert betrachtet. Bei Annahme einer maximalen Fahrzeuggeschwindigkeit von 30 m/s entspricht die Distanz  $t_{\text{dis}} = 0,016$  s einem Längenabstand von 0,48 m. Im Optimierungsverfahren

der Messdatenanalyse von erfassten lokalen Reaktionen wird eine derartige Toleranz für den Optimierungsparameter Auftretenszeitpunkt  $t_i$  berücksichtigt.




**Abbildung 5.5:** Häufigkeiten über  $t_{dis}$  und  $o$   
(119651 Testdatensätze; Klassenbreiten:  $t_{dis}$ : 0,008 s,  $o$ : 0,05)

Die Abbildung 5.6 zeigt die Häufigkeiten der Maximalwerte der NN-Ausgänge  $o$ , die je markierter Achse im Abschnitt  $|t_{dis}| \leq 0,016$  s erhalten wurden. Die dargestellten Ergebnisse beruhen auf 2107 Datensätzen – der Anzahl markierter Achsen. Bei einer Klassenbreite von 0,025 wurden in 99,3 % der Fälle Werte  $o \geq 0,975$  erhalten, Werte  $o \geq 0,70$  wurden sogar mit einer Häufigkeit von 99,9 % festgestellt. Für einen möglichen Grenzwert  $o_{ident}$  von 0,70 erfolgte hiernach im Bereich  $|t_{dis}| \leq 0,016$  s für 99,9 % der markierten Achsen eine korrekte Detektion.



**Abbildung 5.6:** Histogramm für  $max[o]$  bei  $|t_{dis}| \leq 0,016$  s; Ergebnisse je markierter Achse der Testdatensätze (2107 Datensätze; Klassenbreite  $o$ : 0,025)

Die Abbildung 5.7 enthält die Häufigkeiten der Ausgänge  $o$  für die Testdatensätze, welche die Bedingung  $|t_{\text{dis}}| > 0,016$  s erfüllen. Die Ergebnisse basieren auf insgesamt 102378 Datensätzen. Mit einer Häufigkeit von 2,3 % wurden Werte  $o \geq 0,025$  erhalten. Ausgänge größer als 0,70 wurden für 1,45 % der Testdatensätze angegeben. Für einen möglichen Grenzwert  $o_{\text{ident}}$  von 0,70 wurden folglich mit einer Häufigkeit von 1,45 % der Fälle Achsen fälschlicherweise bestimmt. Dementsprechend wurde von den untersuchten Testdatensätzen für 1484 Datensätze keine richtige Detektion durchgeführt.



**Abbildung 5.7:** Histogramm für  $o$  bei  $|t_{\text{dis}}| > 0,016$  s; Ergebnisse je Testdatensatz (102378 Datensätze; Klassenbreite  $o$ : 0,025)

Zur Evaluierung der unterschiedlichen Neuronalen Netze werden der Grenzwert  $o_{\text{ident}}$  der Achsdetektion zu 0,70 gesetzt und die nachfolgenden Definitionen vorgenommen:

$$\text{Richtige Achsdetektion: } o \geq 0,70 \quad \wedge \quad |t_{\text{dis}}| \leq 0,016 \text{ s} \quad (5.5)$$

$$\text{Falsche Achsdetektion: } o \geq 0,70 \quad \wedge \quad |t_{\text{dis}}| > 0,016 \text{ s} \quad (5.6)$$

Die Tabelle 5.2 zeigt die Ergebnisse der Evaluierung für 9 Neuronale Netze unterschiedlicher Anzahl an Eingängen und unterschiedlichen Trainings. Den Netzen lag jeweils der Topologie-Typ 2.1 (vgl. Abbildung 5.1) zu Grunde. Das NN der Nummer 8 wurde zuvor zur Erläuterung des Vorgehens zur Bestimmung der Bewertungskriterien herangezogen. Die Ergebnisse der weiteren NN wurden analog gewonnen.

**Tabelle 5.2:** Evaluierung: Anzahl der Eingänge und Anzahl der Trainingsdatensätze

Nr. [-]	Anzahl der Eingänge des NN	Training		Test	
		Anzahl der Datensätze (DS)		Anteil an Achsdetektionen gemäß Gleichungen 5.5 und 5.6	
		positive DS	negative DS	richtig	falsch
1	20	2000	1000	85,7 %	5,28 %
2	20	2000	2000	86,1 %	4,93 %
3	20	2000	4000	85,8 %	3,54 %
4	40	2000	1000	98,8 %	1,65 %
5	40	2000	2000	98,9 %	1,54 %
6	40	2000	4000	98,7 %	1,45 %
7	50	2000	1000	99,7 %	1,51 %
8	50	2000	2000	99,9 %	1,45 %
9	50	2000	4000	99,5 %	1,34 %

Die Ergebnisse der Tabelle 5.2 lassen hinsichtlich der Einflussgrößen „Anzahl der Eingänge“ und „Anzahl der Trainingsdatensätze“ die folgenden Schlussfolgerungen zu:

Anzahl der Eingänge: Im Vergleich der Ergebnisse für Netze von gleicher Anzahl an Eingängen ist festzustellen, dass NN mit 20 Eingängen das schlechteste Lösungsverhalten zeigten. Die Anteile richtiger Achsdetektionen waren für diese Netze vergleichsweise gering, wohingegen die Anteile falscher Achsdetektionen vergleichsweise hoch ausfielen. Die wesentliche Ursache der festgestellten Performanz ist auf die Verwendung einer offensichtlich zu geringen Anzahl an Eingängen zurückzuführen. Bei einer Abtastfrequenz von 250 Hz und einer angenommenen Fahrzeuggeschwindigkeit von 23 m/s ergibt sich die durch einen Datensatz mit 20 Eingängen repräsentierte Strecke zu  $s = 23 \text{ m/s} \cdot 20 \text{ Eingänge} / 250 \text{ Hz} = 1,8 \text{ m}$ . Der Abstand zweier Achsen einer Tripelachse des Aufliegers von Sattelzügen beträgt üblicherweise  $\sim 1,3 \text{ m}$ . Eine erfasste Wegstrecke von 1,8 m kann daher keine oder genau eine Achse beinhalten. Datensätze, welche aufgrund von Messtoleranz oder -ungenauigkeiten einen oder zwei geringe Ausschläge aufwiesen, wurden wegen der geringen Länge von  $s \approx 1,8 \text{ m}$  durch ein NN mit 20 Eingängen ggf. falsch bewertet. Bei einer Anzahl an Eingängen  $p > 20$  vergrößert sich  $s$ . Im Training eines solchen Netzes enthielten positive Datensätze auch breite Bereiche, welche nicht die Aufzeichnung infolge der direkten Achsbelastung darstellten. In der Anwendung eines NN mit erhöhter Anzahl an Eingängen wurden der NN-Inferenz vergleichsweise mehr Informationen übergeben. Das beste Lösungsverhalten wurde in der Studie für die NN mit 50 Eingängen beobachtet.

Anzahl der Trainingsdatensätze: Hinsichtlich des Anteils der richtig erkannten Achsen zeigten bei gleicher Anzahl an Eingängen die NN, welche auf 2000 positive und 2000 negative Datensätze trainiert wurden, die besten Ergebnisse. Die Verwendung von 1000 negativen Trainingsdatensätzen führte grundsätzlich auf einen erhöhten Anteil an falschen Achsdetektionen. Die Berücksichtigung von 4000 negativen Datensätzen im NN-Training reduzierte die Anteile falscher Detektionen, ging jedoch zugleich mit einer Verminderung der Anteile der richtigen Achsdetektionen einher. Dieses Verhalten könnte auf ein einseitiges Übertraining der NN auf negative Datensätze zurückzuführen sein. Zur Erzielung guter Performanz sind 2000 positive und 2000 negative Datensätze für das NN-Training geeignet.

Aufgrund der sehr guten Ergebnisse für das Netz der Nummer 8 (vgl. Tabelle 5.2) wurden im Rahmen einer weiteren Studie Neuronale Netze unterschiedlicher Topologien mit 50 Eingängen betrachtet, welche auf 2000 positive und 2000 negative Datensätze trainiert wurden. Die Tabelle 5.3 zeigt die erhaltenen Ergebnisse.

**Tabelle 5.3:** Evaluierung: Topologie


Topologie- Typ (vgl. Abbildung 5.1)	Test	
	Anteil der Achsdetektionen gemäß Gleichungen 5.5 und 5.6	
	richtig	falsch
1.1	89,1 %	7,03 %
1.2	96,3 %	1,54 %
2.1	99,9 %	1,45 %
2.2	99,4 %	1,28 %

Zum Einfluss der Topologie auf das Lösungsverhalten der untersuchten Neuronalen Netze kann folgendes festgehalten werden:

- Netze der Typen 1.2 und 2.1 enthielten die gleiche Anzahl an inneren Neuronen bei unterschiedlicher Anzahl an verdeckten Schichten. Mit Netzen des Typs 1.2, die eine innere Schicht aufwiesen, wurden geringfügig schlechtere Ergebnisse als mit Systemen des Typs 2.1, die 2 innere Schichten umfassten, erhalten.
- Die Verwendung einer einzelnen inneren Schicht im Multilayer-Perceptron ist theoretisch ausreichend, in praktischen Anwendungen jedoch nicht immer sinnvoll [Zell03]. Im Vergleich der Ergebnisse für Netze mit einer inneren Schicht (Typ 1) mit den Ergebnissen der Netze mit zwei Schichten (Typ 2) kann festgestellt werden, dass zur Lösung des gegebenen praktischen Problems die Systeme des Typs 2 die deutlich besseren Ergebnisse erzielten.

- Insbesondere die Verarbeitung realer Messwerte erfordert eine ausreichende Fehlertoleranz der Systeme gegenüber ungenauen und teilweise verrauschten Eingabedaten. Die Netzwerke, welche zwei verdeckte Schichten (Typ 2) enthielten, wiesen offensichtlich die hierzu notwendige Netzkapazität auf.

Die Evaluierung von unterschiedlichen Neuronalen Netzen lässt auf Grundlage der in den Tabellen 5.2 und 5.3 dargelegten Ergebnisse erkennen, dass mit Hilfe des Netzes mit 50 Eingängen und zwei verdeckten Schichten, die jeweils 50 Neuronen enthielten, bei einem Training auf 2000 positive und 2000 negative Datensätze die besten Ergebnisse erreicht wurden. Alle markierten Achsen der Testdatensätze wurden richtig detektiert (99,9 %). Ein äußerst geringer Anteil falscher Achsdetektionen wurde beobachtet (1,45 %). Die Anwendung des Neuronalen Netzes wird beispielhaft in der Abbildung 5.8 anhand der Messung zur Überfahrt eines 3-achsigen Lastkraftwagens gezeigt.



**Abbildung 5.8:** Exemplarische Achsdetektion



## 5.3 Analyse globaler Tragwerksreaktionen

### 5.3.1 Messdaten

Die Untersuchungen des Optimierungskerns zur Analyse von erfassten globalen Tragwerksreaktionen finden anhand der Aufzeichnung vom 26.04.2006 von 12:49:32 Uhr bis 12:49:56 Uhr statt. In dieser Zeit fuhren 4 Fahrzeuge in kurzen Abständen über das Bauwerk. In der Auswertung von Messdaten, welche über insgesamt 4 Monate erfasst wurden (siehe Kapitel 6), wurden über einen derart kurzen Zeitraum selten mehr als 4 Fahrzeuge mit einem Gesamtgewicht größer 5 t angetroffen. Die Betrachtung von 4 Fahrzeugen stellt daher eine realitätsnahe Problemstellung dar. Die Messungen einschließlich der Ergebnisse der Auswertung sind in der Abbildung 5.9 dargestellt. Zu Kontrollzwecken wurde die Messung durch eine Videoaufnahme begleitet.




Abbildung 5.9: Erfasste globale Reaktionen: 4 dicht aufeinander folgende Sattelzüge

### 5.3.2 Untersuchte Parameter

Zur Evaluierung des Optimierungsverfahrens der Analyse von erfassten globalen Reaktionen wurden für  $f_{\text{ind}}$  und  $f_{\text{fit}}$  die Werte der Gleichungen 5.7 und 5.8 betrachtet.

$$f_{\text{ind}} = \{ 0,3 ; 0,4 ; 0,5 \} \quad (5.7)$$

$$f_{\text{fit}} = \{ 0,3 ; 0,4 ; 0,5 \} \quad (5.8)$$

Die untersuchten Parameterkombinationen zur Bewertung des Einflusses der Populationsgröße über Generationen gehen aus der Tabelle 5.4 hervor. Die Anzahl der Individuen  $n_{\text{ind},1}$  im Abschnitt 1 und im Übergangsbereich wurden variiert. Der Abschnitt 2

wurde mit einer konstanten Anzahl an Individuen  $n_{\text{ind},2} = 15$  behandelt. Die Anzahl der Generationen  $n_{\text{gen},1}$  und  $n_{\text{gen},2}$  wurde verändert und  $n_{\text{gen},t} = 5$  konstant gehalten. Die zugehörigen Anzahlen an Fitnesswertberechnungen ergeben sich gemäß den Gleichungen 5.1 und 5.2. Die Evaluierung erfolgte nach  $n_{\text{fit},\text{eva}} = 3000$  Fitnesswertberechnungen. Die gewählten Parameter hatten sich im Rahmen von Voruntersuchungen als zweckmäßig zur Lösung der Problemstellung erwiesen.

**Tabelle 5.4:** Untersuchte Parameter; Generationen und Fitnesswertberechnungen

$f_{\text{ind}}$	$f_{\text{fit}}$	$n_{\text{ind},1}$	$n_{\text{ind},2}$	Generationen					Fitnesswertberechnungen				
				$n_{\text{gen},\text{eva}}$	$n_{\text{gen},\text{tot}}$	$n_{\text{gen},1}$	$n_{\text{gen},t}$	$n_{\text{gen},2}$	$n_{\text{fit},\text{eva}}$	$n_{\text{fit},\text{tot}}$	$n_{\text{fit},1}$	$n_{\text{fit},t}$	$n_{\text{fit},2}$
<b>0,3</b>	<b>0,3</b>	50	15	178,5	183	13	5	165	<b>3000</b>	3059	674	240	2145
<b>0,3</b>	<b>0,4</b>	50	15	162,3	169	19	5	145	<b>3000</b>	3087	962	240	1885
<b>0,3</b>	<b>0,5</b>	50	15	146,2	150	25	5	120	<b>3000</b>	3050	1250	240	1560
<b>0,4</b>	<b>0,3</b>	37	15	185,6	190	20	5	165	<b>3000</b>	3057	737	175	2145
<b>0,4</b>	<b>0,4</b>	37	15	172,1	178	28	5	145	<b>3000</b>	3077	1017	175	1885
<b>0,4</b>	<b>0,5</b>	37	15	156,8	162	37	5	120	<b>3000</b>	3067	1332	175	1560
<b>0,5</b>	<b>0,3</b>	30	15	192,7	196	26	5	165	<b>3000</b>	3043	758	140	2145
<b>0,5</b>	<b>0,4</b>	30	15	180,0	187	37	5	145	<b>3000</b>	3091	1066	140	1885
<b>0,5</b>	<b>0,5</b>	30	15	167,3	173	48	5	120	<b>3000</b>	3074	1374	140	1560

**Tabelle 5.5:** Parametersätze, Rekombinations- und Mutationswahrscheinlichkeiten


PS	$f_{\text{ind}}$	$f_{\text{fit}}$	$n_{\text{ind},1}$	$n_{\text{ind},2}$	$n_{\text{gen},\text{tot}}$	$p_{\text{rec},1}$	$p_{\text{rec},2}$	$p_{\text{mutnt},1}$	$p_{\text{mutnt},2}$	$p_{\text{mutt},1}$	$p_{\text{mutt},2}$
<b>1</b>	0,3	0,3	50	15	183	<b>0,7</b>	<b>0,15</b>	<b>0,1</b>	<b>0,6</b>	<b>0,1</b>	<b>0,6</b>
<b>2</b>	0,3	0,3	50	15	183	<b>0,7</b>	<b>0,15</b>	<b>0,1</b>	<b>0,6</b>	<b>0,05</b>	<b>0,4</b>
<b>3</b>	0,3	0,3	50	15	183	<b>0,7</b>	<b>0,15</b>	<b>0,05</b>	<b>0,4</b>	<b>0,1</b>	<b>0,6</b>
<b>4</b>	0,3	0,3	50	15	183	<b>0,7</b>	<b>0,15</b>	<b>0,05</b>	<b>0,4</b>	<b>0,05</b>	<b>0,4</b>
<b>5</b>	0,3	0,3	50	15	183	<b>0,5</b>	<b>0,1</b>	<b>0,1</b>	<b>0,6</b>	<b>0,1</b>	<b>0,6</b>
<b>6</b>	0,3	0,3	50	15	183	<b>0,5</b>	<b>0,1</b>	<b>0,1</b>	<b>0,6</b>	<b>0,05</b>	<b>0,4</b>
<b>7</b>	0,3	0,3	50	15	183	<b>0,5</b>	<b>0,1</b>	<b>0,05</b>	<b>0,4</b>	<b>0,1</b>	<b>0,6</b>
<b>8</b>	0,3	0,3	50	15	183	<b>0,5</b>	<b>0,1</b>	<b>0,05</b>	<b>0,4</b>	<b>0,05</b>	<b>0,4</b>
<b>9 bis 16</b>	0,3	0,4	50	15	169	– obiger Parameterblock –					
<b>17 bis 24</b>	0,3	0,5	50	15	150	– obiger Parameterblock –					
<b>25 bis 32</b>	0,4	0,3	37	15	190	– obiger Parameterblock –					
<b>33 bis 40</b>	0,4	0,4	37	15	178	– obiger Parameterblock –					
<b>41 bis 48</b>	0,4	0,5	37	15	162	– obiger Parameterblock –					
<b>49 bis 56</b>	0,5	0,3	30	15	196	– obiger Parameterblock –					
<b>57 bis 64</b>	0,5	0,4	30	15	187	– obiger Parameterblock –					
<b>65 bis 72</b>	0,5	0,5	30	15	173	– obiger Parameterblock –					

Die Tabelle 5.5 stellt die berechneten Parametersätze zusammen. Ergänzend zu der Tabelle 5.4 umfasst diese Tabelle auch die untersuchten Rekombinations- und Mutationswahrscheinlichkeiten. Die Bedeutung dieser evolutionären Wahrscheinlichkeiten für das Lösungsverhalten des Algorithmus wurde anhand von Parameterpaaren betrachtet. Mit

Hilfe von je zwei Wertepaaren wurde der Einfluss von erhöhten im Vergleich zu verminderten Wahrscheinlichkeiten bewertet. Da je zwei Möglichkeiten für die drei Parameter  $p_{\text{rec}}$ ,  $p_{\text{mutnt}}$  und  $p_{\text{mutt}}$  untersucht wurden, ergibt sich für die einzelnen Kombinationen aus  $f_{\text{ind}}$  mit  $f_{\text{fit}}$  ein Block von  $2^3 = 8$  Parametersätzen. Insgesamt wurden  $8 \cdot 9 = 72$  Parametersätze betrachtet. Je Parametersatz wurden 50 Experimente durchgeführt, was eine Gesamtsumme von  $50 \cdot 72 = 3600$  realisierten Experimenten bedeutet.

### 5.3.3 Ergebnisse

Die Abbildung 5.10 enthält eine Übersicht zu den erhaltenen Ergebnissen. Für die untersuchten 72 Parametersätze wurden die Ergebnisse der Experimente  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  als Mittelwerte im zugehörigen Parametersatz zusammengefasst (Index „mean“).



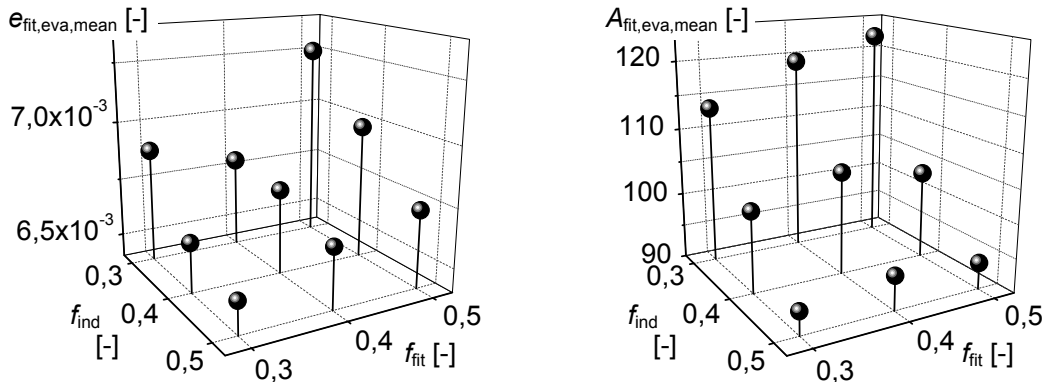
**Abbildung 5.10:** Ergebnisse der Parametersätze:  $A_{\text{fit,eva,mean}}$  aufgetragen über  $e_{\text{fit,eva,mean}}$

Entsprechend der dargestellten Mittelwerte wurden die besten Ergebnisse für Parametersätze gewonnen, in welchen  $f_{\text{ind}} > 0,3$  berücksichtigt wurde. Es ist zu erkennen, dass mit Hilfe der Parameterkombination  $f_{\text{ind}}/f_{\text{fit}} = 0,5/0,3$  sowohl geringe Fitnesswerte  $e_{\text{fit,eva,mean}}$  als auch geringe Flächen  $A_{\text{fit,eva,mean}}$  erzielt wurden. Diese Parameterkombination erscheint daher vielversprechend für den Erhalt einer hohen Lösungsgüte bei hoher Konvergenzgeschwindigkeit.

Hinsichtlich eines minimalen Fitnesswertes  $e_{\text{fit,eva,mean}}$  wurde für den Parametersatz (PS) 50 das beste Ergebnis erzielt. Für diesen Parametersatz ergab sich darüber hinaus die geringste Fitness über alle Experimente mit  $e_{\text{fit,eva,best}} = 6,242 \cdot 10^{-3}$ . Das schlechteste Ergebnis  $e_{\text{fit,eva,mean}}$  wurde für den Parametersatz 21 festgestellt. Dieser Parametersatz enthält mit  $e_{\text{fit,eva,worst}} = 21,898 \cdot 10^{-3}$  die höchste Fitness aller Experimente. PS5 repräsentiert hinsichtlich seines Lösungsverhaltens ein Mittelmaß aus PS50 und PS21.

Die Teilung der Ergebnisse in zwei Gruppen ist auf die untersuchten Parameterpaare der Mutationswahrscheinlichkeiten der terminierten Symbole zurückzuführen. Die Verwendung des Paares  $p_{\text{mutt},1}/p_{\text{mutt},2} = 0,05/0,4$  führte auf offensichtlich bessere Ergebnisse als  $p_{\text{mutt},1}/p_{\text{mutt},2} = 0,1/0,6$ . Auf diesen Sachverhalt wird im Nachfolgenden nochmals eingegangen.

Die Abbildung 5.11 zeigt je Parameterkombination  $f_{\text{ind}}/f_{\text{fit}}$  der Tabelle 5.4 die jeweils beste Lösung der Parametersätze für  $e_{\text{fit,eva,mean}}$  und  $A_{\text{fit,eva,mean}}$ . Den Diagrammen ist eine Tendenz zu entnehmen, wonach die betrachteten Parametersätze mit größerem  $f_{\text{ind}}$  und kleinerem  $f_{\text{fit}}$  geringere Fitnesswerte und höhere Konvergenzgeschwindigkeiten ergaben. Entsprechend der Feststellungen anhand der Abbildung 5.10 wurden für die Parameterkombination  $f_{\text{ind}}/f_{\text{fit}} = 0,5/0,3$  sowohl der geringste Fitnesswert  $e_{\text{fit,eva,mean}}$  als auch die geringste Fläche  $A_{\text{fit,eva,mean}}$  erzielt, wohingegen die Kombination  $f_{\text{ind}}/f_{\text{fit}} = 0,3/0,5$  schlechtere Ergebnisse ergab.




**Abbildung 5.11:** Jeweils beste Lösungen  $e_{\text{fit,eva,mean}}$  und  $A_{\text{fit,eva,mean}}$  für Parameterkombinationen von  $f_{\text{ind}}$  mit  $f_{\text{fit}}$

Die Abbildung 5.12 zeigt als Boxplots (siehe auch Anhang C) die erhaltenen Fitnesswerte  $e_{\text{fit,eva}}$  aller Experimente der Parameterkombinationen zur Bewertung des Einflusses der Populationsgrößenentwicklung über Generationen ( $f_{\text{ind}}/f_{\text{fit}}$ ), der Rekombinations- ( $p_{\text{rec},1}/p_{\text{rec},2}$ ) und der Mutationswahrscheinlichkeiten ( $p_{\text{mutnt},1}/p_{\text{mutnt},2}$  und  $p_{\text{mutt},1}/p_{\text{mutt},2}$ ). Bezüglich des Einflusses der Entwicklung der Populationsgröße über die Generationen ist festzustellen, dass bei geringerer Streuung und niedrigerem Maximalwert mit Hilfe der Kombination  $f_{\text{ind}}/f_{\text{fit}} = 0,5/0,3$  im Vergleich zu  $f_{\text{ind}}/f_{\text{fit}} = 0,3/0,5$  die besseren Ergebnisse erhalten wurden. Ähnlich eindeutige Schlussfolgerungen können für die betrachteten Mutationswahrscheinlichkeiten der terminierten Symbole gezogen werden: Die verminderten Wahrscheinlichkeiten ( $p_{\text{mutt},1}/p_{\text{mutt},2} = 0,05/0,4$ ) ergaben deutlich zuverlässiger geringere Fitnesswerte  $e_{\text{fit,eva}}$ . Dieser Zusammenhang wurde bereits anhand der

Übersicht der Abbildung 5.10 festgestellt. Die Ergebnisse zu den betrachteten Parameterkombinationen  $p_{\text{rec},1}/p_{\text{rec},2}$  und  $p_{\text{mutnt},1}/p_{\text{mutnt},2}$  unterscheiden sich nur geringfügig. Für das Paar  $p_{\text{rec},1}/p_{\text{rec},2} = 0,7/0,15$  bzw.  $p_{\text{mutnt},1}/p_{\text{mutnt},2} = 0,1/0,6$  wurden in Detailbetrachtungen mit etwas höherer Häufigkeit die jeweils geringeren Werte  $e_{\text{fit,eva}}$  erzielt.

Die Schiefe, welche grundsätzlich den im Boxplot dargestellten Ergebnissen zu Grunde liegt, ist auf das Lösungsverhalten der Evolutionären Algorithmen zurückzuführen: Nach  $n_{\text{fit,eva}}$  Fitnesswertberechnungen umfasst die Population der Individuen mehrere Lösungskandidaten, die sich in weiten Teilen angeglichen haben – die Kandidaten repräsentieren ähnliche, sehr gute Lösungen der Problemstellung. Da Minimierungsprobleme untersucht werden, konzentrieren sich die Fitnesswerte  $e_{\text{fit,eva}}$  im Bereich von sehr kleinen Werten.


Fitnesswerte  $e_{\text{fit,eva}}$  gleich 0 werden in der realen Anwendung nicht erreicht. Aufgrund der vorhandenen Messtoleranzen und -ungenauigkeiten nähern sich die Werte im Optimierungsprozess asymptotisch einem inhärenten Fehler  $e_{\text{lim}}$  an.



**Abbildung 5.12:** Boxplots der Fitnesswerte  $e_{\text{fit,eva}}$  der untersuchten Parameterkombinationen (Basis je Plot:  $f_{\text{ind}}/f_{\text{fit}}$ : 400 Datensätze; Rest: 1800 Datensätze)


Die Abbildung 5.13 enthält die Ergebnisse  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  der 50 Experimente zu den Parametersätzen (PS) 50, 5 und 21 (vgl. Abbildung 5.10). Die Schiefe der Ergebnisse für  $e_{\text{fit,eva}}$  wurde zuvor erläutert. Die Werte  $A_{\text{fit,eva}}$  zeigen kaum Schiefe, da der Flächeninhalt der Fitnesswertentwicklung dem stochastischen Gesamtablauf der Evolutionären Algorithmen unterliegt. Die Abbildung lässt erkennen, dass mit Hilfe von PS50 im Vergleich zu PS5 und PS21 äußerst geringe Fitnesswerte  $e_{\text{fit,eva}}$  bei sehr kleiner Streuung

sowie geringen Ausreißern erzielt wurden. Der Parametersatz 50 ergab sowohl eine hohe Lösungsgüte als auch eine sehr gute Konvergenzgeschwindigkeit.



**Abbildung 5.13:** Boxplots der Experimente zu den Parametersätzen 50, 5 und 21:  
a) Lösungen  $e_{\text{fit,eva}}$ , b) Lösungen  $A_{\text{fit,eva}}$  (Basis je Plot: 50 Datensätze)

Die Abbildung 5.14 zeigt die Fitnesswertentwicklung für den Parametersatz 50. Die Fitnesswerte der 50 Experimente des Parametersatzes wurden hierzu gemittelt (Index „mean“). Der Abbildung können die Entwicklung der maximalen Fitness  $e_{\text{fit,max,mean}}$ , der durchschnittlichen Fitness  $e_{\text{fit,avg,mean}}$  und der minimalen Fitness  $e_{\text{fit,min,mean}}$  entnommen werden. Darüber hinaus enthält die Abbildung den Fortschritt der Standardabweichung  $e_{\text{fit,min,stdv}}$  der minimalen Fitness der Experimente.




**Abbildung 5.14:** Fitnesswertentwicklung Parametersatz 50

Im Verlauf der Fitnesswertentwicklung ist der Übergangsbereich der Parameteradaption deutlich zu erkennen. Ab  $n_{\text{fit,eva}} = 2500$  fand keine maßgebliche Verbesserung des Fitnessergebnisses mehr statt. Die Werte  $e_{\text{fit,min,stdv}}$  betragen für  $n_{\text{fit,eva}} \geq 2500$  annähernd 0. Im Rahmen der Analyse von kontinuierlich erfassten Messdaten könnte der Algorithmus gegebenenfalls vorzeitig beendet werden.

## 5.4 Analyse lokaler Tragwerksreaktionen

### 5.4.1 Messdaten

Das Optimierungsverfahren zur Analyse der lokalen Reaktionen wird mit Hilfe der Aufzeichnung zur Überfahrt eines Fahrzeugs evaluiert. Das Fahrzeug – ein 5-achsiger Sattelzug – wurde am 26.04.2006 um 12:59:36 Uhr beobachtet. Fahrzeuge mit bis zu 5 Achsen wurden im Rahmen der Analyse einer 4-monatigen Messung mit einer Häufigkeit von 98 % angetroffen (siehe Kapitel 6). Die Aufzeichnung inklusive der Ergebnisse der Auswertung sind der Abbildung 5.15 zu entnehmen. Die seinerzeitige Messung wurde durch Videoerfassung begleitet.



**Abbildung 5.15:** Erfasste lokale Reaktionen: Sattelzug mit  $Q_{\text{tot}} = 415,5 \text{ kN}$

### 5.4.2 Untersuchte Parameter

Der Einfluss der Populationsgröße über Generationen wurde anhand der Ergebnisse für die Kombinationen aus  $f_{\text{ind}}$  mit  $f_{\text{fit}}$  gemäß den Gleichungen 5.9 und 5.10 evaluiert.

$$f_{\text{ind}} = \{ 0,5 ; 0,6 ; 0,7 \} \quad (5.9)$$

$$f_{\text{fit}} = \{ 0,3 ; 0,4 ; 0,5 \} \quad (5.10)$$

Die Tabelle 5.6 stellt die sich ergebenden Kombinationen der beiden Werte einschließlich der zu Grunde liegenden evolutionären Parameter zusammen. Die Tabelle 5.7 zeigt die Parametersätze, welche in den Untersuchungen betrachtet wurden.

Die Evaluierung erfolgte für Ergebnisse nach  $n_{\text{fit,eva}} = 3000$  Fitnesswertberechnungen. Die gewählten Parameter wurden im Rahmen von Voruntersuchungen als aussichtsreich zur Lösung der Problemstellung festgestellt.

**Tabelle 5.6:** Untersuchte Parameter; Generationen und Fitnesswertberechnungen

$f_{\text{ind}}$	$f_{\text{fit}}$	$n_{\text{ind},1}$	$n_{\text{ind},2}$	Generationen					Fitnesswertberechnungen				
				$n_{\text{gen,eva}}$	$n_{\text{gen,tot}}$	$n_{\text{gen},1}$	$n_{\text{gen},t}$	$n_{\text{gen},2}$	$n_{\text{fit,eva}}$	$n_{\text{fit,tot}}$	$n_{\text{fit},1}$	$n_{\text{fit},t}$	$n_{\text{fit},2}$
<b>0,5</b>	<b>0,3</b>	40	20	138,9	143	18	5	120	<b>3000</b>	3074	724	190	2160
<b>0,5</b>	<b>0,4</b>	40	20	130,0	136	26	5	105	<b>3000</b>	3108	1028	190	1890
<b>0,5</b>	<b>0,5</b>	40	20	120,0	130	35	5	90	<b>3000</b>	3180	1370	190	1620
<b>0,6</b>	<b>0,3</b>	33	20	144,6	148	23	5	120	<b>3000</b>	3061	746	155	2160
<b>0,6</b>	<b>0,4</b>	33	20	137,4	143	33	5	105	<b>3000</b>	3101	1056	155	1890
<b>0,6</b>	<b>0,5</b>	33	20	130,9	137	42	5	90	<b>3000</b>	3110	1335	155	1620
<b>0,7</b>	<b>0,3</b>	28	20	150,4	153	28	5	120	<b>3000</b>	3046	756	130	2160
<b>0,7</b>	<b>0,4</b>	28	20	145,1	150	40	5	105	<b>3000</b>	3088	1068	130	1890
<b>0,7</b>	<b>0,5</b>	28	20	139,8	147	52	5	90	<b>3000</b>	3130	1380	130	1620

**Tabelle 5.7:** Parametersätze, Rekombinations- und Mutationswahrscheinlichkeiten

PS	$f_{\text{ind}}$	$f_{\text{fit}}$	$n_{\text{ind},1}$	$n_{\text{ind},2}$	$n_{\text{gen,tot}}$	$p_{\text{rec},1}$	$p_{\text{rec},2}$	$p_{\text{mutnt},1}$	$p_{\text{mutnt},2}$	$p_{\text{mutt},1}$	$p_{\text{mutt},2}$
<b>1</b>	0,5	0,3	40	20	143	<b>0,5</b>	<b>0,15</b>	<b>0,15</b>	<b>0,6</b>	<b>0,15</b>	<b>0,6</b>
<b>2</b>	0,5	0,3	40	20	143	<b>0,5</b>	<b>0,15</b>	<b>0,15</b>	<b>0,6</b>	<b>0,1</b>	<b>0,4</b>
<b>3</b>	0,5	0,3	40	20	143	<b>0,5</b>	<b>0,15</b>	<b>0,1</b>	<b>0,4</b>	<b>0,15</b>	<b>0,6</b>
<b>4</b>	0,5	0,3	40	20	143	<b>0,5</b>	<b>0,15</b>	<b>0,1</b>	<b>0,4</b>	<b>0,1</b>	<b>0,4</b>
<b>5</b>	0,5	0,3	40	20	143	<b>0,4</b>	<b>0,1</b>	<b>0,15</b>	<b>0,6</b>	<b>0,15</b>	<b>0,6</b>
<b>6</b>	0,5	0,3	40	20	143	<b>0,4</b>	<b>0,1</b>	<b>0,15</b>	<b>0,6</b>	<b>0,1</b>	<b>0,4</b>
<b>7</b>	0,5	0,3	40	20	143	<b>0,4</b>	<b>0,1</b>	<b>0,1</b>	<b>0,4</b>	<b>0,15</b>	<b>0,6</b>
<b>8</b>	0,5	0,3	40	20	143	<b>0,4</b>	<b>0,1</b>	<b>0,1</b>	<b>0,4</b>	<b>0,1</b>	<b>0,4</b>
<b>9 bis 16</b>	0,5	0,4	40	20	136	– obiger Parameterblock –					
<b>17 bis 24</b>	0,5	0,5	40	20	130	– obiger Parameterblock –					
<b>25 bis 32</b>	0,6	0,3	33	20	148	– obiger Parameterblock –					
<b>33 bis 40</b>	0,6	0,4	33	20	143	– obiger Parameterblock –					
<b>41 bis 48</b>	0,6	0,5	33	20	137	– obiger Parameterblock –					
<b>49 bis 56</b>	0,7	0,3	28	20	153	– obiger Parameterblock –					
<b>57 bis 64</b>	0,7	0,4	28	20	150	– obiger Parameterblock –					
<b>65 bis 72</b>	0,7	0,5	28	20	147	– obiger Parameterblock –					


In Anlehnung an die Evaluierung des Optimierungsverfahrens zur Auswertung der globalen Tragwerksreaktionen wurde der Einfluss der Rekombinations- und Mutationswahrscheinlichkeiten auf das Lösungsverhalten mit Hilfe von Parameterpaaren bewer-



tet. Für die Wahrscheinlichkeiten  $p_{\text{rec}}$ ,  $p_{\text{mutnt}}$  und  $p_{\text{mutt}}$  folgt ein Parameterblock, der sich nach jeweils 8 Parametersätzen wiederholt. Insgesamt wurden – wie auch zur Evaluierung des Verfahrens zur Analyse der globalen Reaktionen – 72 Parametersätze betrachtet, je Parametersatz 50 Experimente durchgeführt und somit eine Gesamtsumme von  $50 \cdot 72 = 3600$  Experimenten realisiert.

### 5.4.3 Ergebnisse

Die Abbildung 5.16 zeigt eine Übersicht der Ergebnisse für die untersuchten 72 Parametersätze. Die Ergebnisse der Experimente  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  wurden als Mittelwerte (Index „mean“) im zugehörigen Parametersatz zusammengefasst.



**Abbildung 5.16:** Ergebnisse der Parametersätze:  $A_{\text{fit,eva,mean}}$  aufgetragen über  $e_{\text{fit,eva,mean}}$

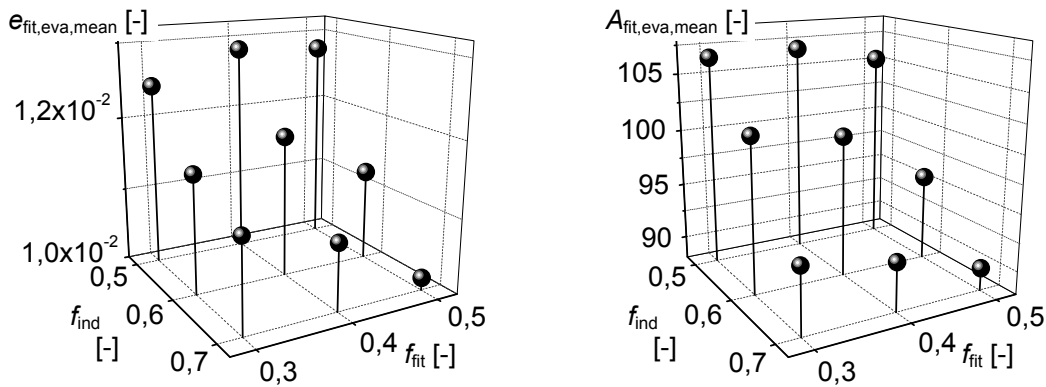
Hinsichtlich minimaler Werte  $e_{\text{fit,eva,mean}}$  und  $A_{\text{fit,eva,mean}}$  wurden die besten Ergebnisse für Parametersätze mit  $f_{\text{ind}} = 0,7$  gewonnen. Die Parameterkombination  $f_{\text{ind}}/f_{\text{fit}} = 0,7/0,5$  ergab sowohl eine hohe Lösungsgüte bei geringen Fitnesswerten  $e_{\text{fit,eva,mean}}$  als auch eine hohe Konvergenzgeschwindigkeit bei geringen Flächen  $A_{\text{fit,eva,mean}}$ . Diese Parameterkombination erscheint demnach vorteilhaft für den Erhalt von guten Ergebnissen.

Die minimale gemittelte Fitness  $e_{\text{fit,eva,mean}}$  wurde für den Parametersatz (PS) 72 erhalten. Der maximale gemittelte Fitnesswert ergab sich für PS1. Der beste Fitnesswert aller Experimente wurde mit  $e_{\text{fit,eva,best}} = 6,365 \cdot 10^{-3}$  für ein Experiment des PS54 erreicht. Die schlechteste Fitness über alle Experimente stellte sich für den Parametersatz 6 mit  $e_{\text{fit,eva,worst}} = 33,409 \cdot 10^{-3}$  ein.

Die Zweiteilung der Ergebnisse steht im Zusammenhang mit den gewählten Mutationswahrscheinlichkeiten  $p_{\text{mutt}}$  der terminierten Symbole. Im Vergleich zu der Wahl

$p_{\text{mutt},1}/p_{\text{mutt},2} = 0,15/0,6$  führte das Parameterpaar der verminderten Wahrscheinlichkeiten  $p_{\text{mutt},1}/p_{\text{mutt},2} = 0,1/0,4$  auf augenscheinlich bessere Ergebnisse. Ein ähnlicher Zusammenhang wurde für die entsprechenden Ergebnisse der Evaluierung des Verfahrens zur Analyse der globalen Reaktionen anhand der Abbildung 5.10 festgestellt.


Die Abbildung 5.17 enthält je Parameterkombination  $f_{\text{ind}}/f_{\text{fit}}$  der Tabelle 5.6 die jeweils beste Lösung der Parametersätze für  $e_{\text{fit,eva,mean}}$  und  $A_{\text{fit,eva,mean}}$ . Gemäß den Ergebnissen wurden in der Tendenz mit größerem  $f_{\text{ind}}$  und größerem  $f_{\text{fit}}$  höhere Lösungsgüten sowie höhere Konvergenzgeschwindigkeiten erzielt. Mit Hilfe der Parameterkombination  $f_{\text{ind}}/f_{\text{fit}} = 0,7/0,5$  wurden sowohl die geringste Fitness  $e_{\text{fit,eva,mean}}$  als auch die geringste Fläche  $A_{\text{fit,eva,mean}}$  erhalten. PS72 basiert auf dieser Parameterwahl; PS54 berücksichtigt den Parameter  $f_{\text{ind}} = 0,7$ . Die Kombination  $f_{\text{ind}}/f_{\text{fit}} = 0,5/0,3$  führte auf ein vergleichsweise schlechteres Lösungsverhalten. PS1 und PS6 berücksichtigen diese Parameterwahl.



**Abbildung 5.17:** Jeweils beste Lösungen  $e_{\text{fit,eva,mean}}$  und  $A_{\text{fit,eva,mean}}$  für Parameterkombinationen von  $f_{\text{ind}}$  mit  $f_{\text{fit}}$


Die Abbildung 5.18 zeigt die berechneten Fitnesswerte  $e_{\text{fit,eva}}$  zu den Experimenten der untersuchten Parameterkombinationen  $f_{\text{ind}}/f_{\text{fit}}$ ,  $p_{\text{rec},1}/p_{\text{rec},2}$ ,  $p_{\text{mutnt},1}/p_{\text{mutnt},2}$  und  $p_{\text{mutt},1}/p_{\text{mutt},2}$ . Die Schiefe der Ergebnisse wird durch das allgemeine Lösungsverhalten der evolutionären Algorithmen begründet und wurde für die entsprechenden Ergebnisse der Evaluierung des Analyseverfahrens der globalen Reaktionen bereits erläutert (vgl. Abbildung 5.12). Hinsichtlich des Einflusses der Populationsgrößenentwicklung über die Generationen ist festzustellen, dass die Berücksichtigung von  $f_{\text{ind}}/f_{\text{fit}} = 0,7/0,5$  im Vergleich zu  $f_{\text{ind}}/f_{\text{fit}} = 0,5/0,3$  den Erhalt besserer Ergebnisse unterstützte. Zusätzlich zu einem erheblich geringeren arithmetischen Mittel unterliegen die Ergebnisse von  $f_{\text{ind}}/f_{\text{fit}} = 0,7/0,5$  einer geringeren Streuung. Die Ergebnisse der Paare  $p_{\text{rec},1}/p_{\text{rec},2}$  und  $p_{\text{mutnt},1}/p_{\text{mutnt},2}$  zur Bewertung des Einflusses der Rekombination und der Mutation von nicht-terminierten Symbolen unterscheiden sich kaum. Mit Hilfe der Parameter  $p_{\text{rec},1}/p_{\text{rec},2} = 0,4/0,1$  bzw.

$p_{\text{mutnt},1}/p_{\text{mutnt},2} = 0,1/0,4$  wurden in Nebenuntersuchungen mit etwas höherer Häufigkeit die jeweils kleineren Fitnesswerte  $e_{\text{fit,eva}}$  erhalten. Zur Mutation der terminierten Symbole ergab das Wertepaar  $p_{\text{mutt},1}/p_{\text{mutt},2} = 0,1/0,4$  zuverlässiger geringere Werte  $e_{\text{fit,eva}}$ .



**Abbildung 5.18:** Boxplots der Fitnesswerte  $e_{\text{fit,eva}}$  der untersuchten Parameterkombinationen (Basis je Plot:  $f_{\text{ind}}/f_{\text{fit}}$ : 400 Datensätze; Rest: 1800 Datensätze)


Die Abbildung 5.19 zeigt vergleichend die Ergebnisse  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  der 50 Experimente der Parametersätze (PS) 72, 54 und 1 (vgl. auch Abbildung 5.16). Im Vergleich zu PS54 und PS1 weisen die Ergebnisse für PS72 die geringeren Ausreißer sowie die kleineren Interquartilabstände auf. Für PS72 konzentrieren sich die Werte  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  im Bereich von sehr kleinen Werten. Der Parametersatz ermöglichte somit eine hohe Lösungsgüte und eine hohe Konvergenzgeschwindigkeit.



**Abbildung 5.19:** Boxplots der Experimente zu den Parametersätzen 72, 54 und 1:  
a) Lösungen  $e_{\text{fit,eva}}$ , b) Lösungen  $A_{\text{fit,eva}}$  (Basis je Plot: 50 Datensätze)

Die Abbildung 5.20 enthält die Fitnesswertentwicklung für den Parametersatz 72. Die gezeigten Verläufe stellen die gemittelten (Index „mean“) Ergebnisse  $e_{\text{fit}}$  der 50 Experimente dar. Die Parameteradaption im Übergangsbereich  $n_{\text{fit},1} \leq n_{\text{fit}} \leq n_{\text{fit},1} + n_{\text{fit},t}$  ist anhand der Fitnesswertentwicklung klar zu erkennen. Da ein Minimierungsproblem vorliegt, ist der Abbildung ebenfalls die Entwicklung der Standardabweichung (Index „stdv“) der minimalen Fitness  $e_{\text{fit},\text{min}}$  der Experimente zu entnehmen.

Ab  $n_{\text{fit}} = 2800$  findet keine nennenswerte Verbesserung von  $e_{\text{fit},\text{min},\text{mean}}$  statt. Die Standardabweichung  $e_{\text{fit},\text{min},\text{stdv}}$  beträgt  $\approx 0$ . Zur Anwendung des entwickelten Verfahrens in der Analyse von realen Messungen könnte der Optimierungsprozess ggf. vorzeitig beendet werden.



**Abbildung 5.20:** Fitnesswertentwicklung Parametersatz 72

## 5.5 Diskussion der Ergebnisse

Die Evaluierung der entwickelten mehrschichtigen vollverknüpften feedforward Netzwerke und der evolutionären Optimierungsverfahren erfolgte auf der Basis eines konkreten Anwendungsproblems. Die zu Grunde gelegten Messungen wurden an einem Brückenbauwerk, welches als repräsentativ angesehen werden kann, gewonnen. Die erhaltenen Ergebnisse lassen schlussfolgern, dass sowohl die Neuronalen Netze als auch die evolutionären Optimierungsverfahren probate Mittel zur Lösung von Problemstellungen der Lastidentifikation darstellen.

### *Achsdetektion mit Hilfe künstlicher Neuronaler Netze*

Zur Evaluierung der Neuronalen Netze wurden Trainings- und Testdatensätze verwendet, die je aus einer Stunde Messdatenaufzeichnung erstellt wurden. Trainings- und Testdatensätze waren nicht identisch.

Für das Multilayer-Perceptron mit 50 Eingängen und zwei verdeckten Schichten, die jeweils 50 innere Neuronen enthielten, trainiert auf 2000 positive und 2000 negative Datensätze, wurden in der Studie die besten Ergebnisse erreicht. Sämtliche markierten Achsen der Testdatensätze wurden erkannt (99,9 %). Der Anteil falscher Achsdetektion fiel vergleichsweise gering aus (1,45 %).

Das Neuronale Netz eignet sich aufgrund der vollständig korrekten Achsdetektion sehr gut zur Verwendung im Rahmen des Optimierungsverfahrens der Messdatenanalyse erfasster lokaler Reaktionen. Im Entwurf des Optimierungsalgorithmus werden die für dieses Neuronale Netz gewonnenen Erkenntnisse berücksichtigt: Im Optimierungsprozess ist die Aufnahme weiterer Achsen nicht erforderlich, das Entfernen von möglicherweise falsch detektierten Achsen ist jedoch aufzunehmen. Sowohl die Anzahl zu untersuchender Optimierungsparameter als auch der Umfang der Optimierungsaufgabe können durch das klar deutbare NN-Verhalten erheblich verringert werden.

### *Evolutionäre Optimierungskerne zur Analyse erfasster Tragwerksreaktionen*

Die beiden evolutionären Optimierungsverfahren zur Analyse von erfassten globalen und lokalen Tragwerksreaktionen wurden jeweils anhand von 72 definierten Parametersätzen evaluiert. Zur Absicherung der Ergebnisse wurden je Parametersatz 50 Experimente durchgeführt. Je Verfahren wurden insgesamt  $72 \cdot 50 = 3600$  Berechnungen vorgenommen.

Obwohl beide Optimierungsverfahren auf der Basis von Ergebnissen nach  $n_{\text{fit,eva}} = 3000$  Fitnesswertberechnungen beurteilt wurden, können die jeweils erhaltenen Ergebnisse  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  nicht direkt miteinander verglichen werden. Trotz ähnlicher Fitnessfunktionen (vgl. Gleichungen 3.2 und 3.6), die im Wesentlichen die normierte und quadrierte Abweichung der berechneten zu den gemessenen Werten berücksichtigen, existieren bedeutsame Unterschiede, die sich auf die Größenordnung der Ergebniswerte  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$  auswirken:

- Zur Messung der beiden Reaktionsarten wurden verschiedene Sensoren eingesetzt. Globale Tragwerksreaktionen wurden mit Hilfe von Dehnungsmessstreifen erfasst. Lokale Reaktionen wurden mit induktiven Wegaufnehmern aufgenommen. Die Wegaufnehmer wiesen einen höheren Toleranzbereich auf. Infolge der höheren Messgenauigkeiten ergaben sich größere quadrierte Fehler in der Fitnesswertbestimmung.
- Die Fitnessfunktion des Optimierungsverfahrens zur Analyse der lokalen Reaktionen enthält Straffunktionen. Die Unterschreitung eines vordefinierten minimalen Achsabstands sowie die Unterschreitung einer angestrebten Achsanzahl werden im Optimierungsprozess zugelassen, jedoch in der Fitnesswertermittlung bestraft. Derartige Straffunktionen sind in der Fitnessfunktion der globalen Reaktionen nicht enthalten.

Ein Ergebnis-Vergleich kann daher nur über das beobachtete, grundsätzliche Lösungsverhalten für die gewählten Parameter erfolgen:

Populationsgröße über Generationen: Die Verwendung eines erhöhten Werts  $f_{\text{ind}}$  wirkte sich positiv auf das Lösungsverhalten beider Optimierungsverfahren aus. Die Ergebnisse bezüglich der Wahl des Werts  $f_{\text{fit}}$  sind für die beiden Verfahren gegenläufig: Zur Auswertung globaler Reaktionen hat sich ein geringerer Wert und zur Auswertung lokaler Reaktionen ein erhöhter Wert als geeignet dargestellt.

Rekombinations- und Mutationswahrscheinlichkeiten: Im Vergleich des Lösungsverhaltens für die Parameterpaare  $p_{\text{rec}}$  und  $p_{\text{mutnt}}$  ist festzustellen, dass sich die erzielten Ergebnisse nicht maßgeblich unterscheiden. Mit Hilfe erhöhter Werte  $p_{\text{rec}}$  wurden in der Auswertung globaler Reaktionen geringfügig bessere Ergebnisse erzielt. Verminderte Werte  $p_{\text{rec}}$  führten für die lokalen Reaktionen zu etwas geringeren Werten  $e_{\text{fit,eva}}$  und  $A_{\text{fit,eva}}$ . Gleichmaßen zeigte die Verwendung erhöhter Wahrscheinlichkeiten  $p_{\text{mutnt}}$  in der Auswertung globaler Reaktionen einen günstigen Einfluss auf das Lösungsverhalten.

Mit Hilfe verminderter Werte  $p_{mutnt}$  wurden in der Analyse lokaler Reaktionen etwas bessere Ergebnisse erreicht. Lediglich die Ergebnisse der Untersuchungen zur Wahl der Wahrscheinlichkeiten  $p_{mutt}$  erlauben eindeutige Schlussfolgerungen: Das Lösungsverhalten beider Optimierungsverfahren wurde durch die Verwendung verminderter Werte für  $p_{mutt}$  verbessert. Sowohl deutlich geringere Werte  $e_{fit,eva}$  und  $A_{fit,eva}$  als auch geringere Streubreiten der Ergebnisse wurden hiermit erreicht.

Zur Anwendung der entwickelten Ansätze im Rahmen der Analyse von realen Messdaten stellt die Tabelle 5.8 die Parameterwerte zusammen, welche die besten Resultate ergaben.

**Tabelle 5.8:** Geeignete Parameter zur Analyse von globalen und lokalen Reaktionen

Parameter	Globale Reaktionen (PS50)			Lokale Reaktionen (PS72)		
	Abschnitt 1 (i = 1)	Übergang (i = t)	Abschnitt 2 (i = 2)	Abschnitt 1 (i = 1)	Übergang (i = t)	Abschnitt 2 (i = 2)
$n_{fit,i}$	758	140	2145	1380	130	1620
$n_{gen,i}$	26	5	165	52	5	90
$n_{ind,i}$	30	30	15	28	28	20
$n_{sel,i}$	2	2	2	2	2	2
$n_{eli,i}$	2	2	2	2	2	2
$n_{rec,i}$	1	1	1	1	1	1
$n_{mut,i}$	1	1	1	1	1	1
$p_{rec,i}$	0,7	0,7-0,15	0,15	0,4	0,4-0,1	0,1
$p_{mutnt,i}$	0,1	0,1-0,6	0,6	0,1	0,1-0,4	0,4
$p_{mutt,i}$	0,05	0,05-0,4	0,4	0,1	0,1-0,4	0,4

In Ergänzung zur umgesetzten Parameteradaption könnte ggf. eine Anpassung der Parameter in Abhängigkeit von der Anzahl an Optimierungsgrößen berücksichtigt werden. Die Komplexität der Optimierungsaufgabe der Analyse erfasster globaler Reaktionen steigt mit der Anzahl zu untersuchender Fahrzeuge. Gleichmaßen erhöht sich der Umfang der Optimierungsaufgabe der lokalen Reaktionen mit der Anzahl der Achsen eines betrachteten Fahrzeugs. Entsprechend der vorhandenen Anzahl an Optimierungsgrößen könnten die evolutionären Parameter im Optimierungsprozess adaptiert werden.





# Kapitel 6

## Anwendung

### 6.1 Bauwerk, durchgeführte Messungen

#### 6.1.1 Systemdaten


Die entwickelten und implementierten Methoden wurden zur Auswertung von Messdaten, die im Rahmen der Dauerüberwachung des Überbaus einer Betonbrücke gewonnen wurden, eingesetzt.

Das Bauwerk befindet sich im Zuge einer stark befahrenen Bundesautobahn und wurde in den 1970er Jahren errichtet. Es bestehen zwei getrennte Überbauten zur Aufnahme der Richtungsfahrbahnen. Der Querschnitt der Überbauten ist ein einzelliger Hohlkasten mit einer Höhe von 4,20 m und einer Gesamtbreite von ca. 15 m. Die Überbauten sind durchlaufende Systeme über 12 Felder mit Spannweiten zwischen 34,35 m und 70 m. Die Gesamtlänge beträgt 600 m. Die Herstellung erfolgte im Taktschiebverfahren. In Längsrichtung weisen die Überbauten in der Fahrbahn- und Bodenplatte einen geraden und in den Stegen einen gekrümmten Spanngliedverlauf auf. Zur Vorspannung von Fahrbahn- und Bodenplatte wurden Spannstäbe Ø 32 und Ø 36 des Typs Dywidag St. 85/105 verwendet. Die Vorspannung in den Stegen wurde mit Litzen Suspa IV St. 150/170 aufgebracht. Die Fahrbahnplatte ist quervorgespannt mit Stäben Ø 32 Dywidag St. 85/105. Die Betonfestigkeitsklasse ist in der Bestandsstatik nach der seinerzeit gültigen DIN 1045 mit B 450 angegeben. Das Bauwerk ist in die Brückenklasse 60 gemäß DIN 1072 eingestuft.

Zur Bauwerksüberwachung wurde ein Feldquerschnitt gemäß Abbildung 6.1 instrumentiert. Im Bereich der Bodenplatte in direkter Nähe zu den Stegen wurden mit Hilfe von Dehnungsmessstreifen Spannstahldehnungsänderungen  $\Delta\varepsilon_{m,1}$  und  $\Delta\varepsilon_{m,2}$  aufgezeichnet.

Die Doppelpunktmessung an beiden Stegen ermöglichte die messtechnische Erfassung der Querverteilung der Lasten. Zum Erhalt von lokalen Plattenreaktionen wurden mit induktiven Wegaufnehmern auf dem Beton an der Unterseite der Fahrbahnplatte Verformungen erfasst. Vorausgegangene Vergleichsrechnungen sowie Zustandsuntersuchungen vor Ort zeigten, dass sich die Platte am Ort der Sensoren im Zustand I befindet. Innerhalb der Messlänge der Sensoren befanden sich somit keine Risse, die das Messergebnis verfälscht hätten. Die Umrechnung der Verformungen in Dehnungen wurde über die Basislänge der Wegaufnehmer durchgeführt. Die Messung  $\Delta\varepsilon_{m,3}$  erfolgte in Längs- und  $\Delta\varepsilon_{m,4}$  in Querrichtung.

Zur genauen Bewertung der Querschnittsbeanspruchung wurden zusätzlich Temperaturmessungen vorgenommen. Umgebungslufttemperaturen innen ( $T_{m,i}$ ) und außen ( $T_{m,a}$ ) sowie Betontemperaturen ( $T_{m,1u}$ ,  $T_{m,1o}$ ,  $T_{m,2u}$  und  $T_{m,2o}$ ) wurden mit konventionellen Thermoelementen aufgenommen. Die Messdatenerfassung erfolgte kontinuierlich und digital mit Hilfe einer PC-gestützten Anlage.



**Abbildung 6.1:** Anwendungsbeispiel: Statisches System und Messquerschnitt

Zur Gewährleistung von Langzeitstabilität und Signalsicherheit wurden hochwertige Sensoren eingesetzt und die Aufzeichnung einzelner Größen durch die Verwendung mehrerer Sensoren abgesichert. Zum Schutz vor Witterungsbedingungen wurden die Messelemente mit Kunststoffabdeckungen und Silikonabdichtungen versehen.

Die Sensoren  $\Delta\varepsilon_{m,1}$  und  $\Delta\varepsilon_{m,2}$  zeichneten vornehmlich globale Überbaureaktionen auf, wohingegen die Messsignale der Sensoren  $\Delta\varepsilon_{m,3}$  und  $\Delta\varepsilon_{m,4}$  durch lokale Plattenreaktionen geprägt waren. Entsprechend der Erläuterungen des Kapitels 3.2 (vgl. auch Tabelle 3.2) wurden  $\Delta\varepsilon_{m,1}$  und  $\Delta\varepsilon_{m,2}$  mit 10 Hz,  $\Delta\varepsilon_{m,4}$  mit 100 Hz und  $\Delta\varepsilon_{m,3}$  mit 250 Hz abgetastet. Die Temperaturmessung erfolgte alle 15 min.

Nachfolgend werden Erkenntnisse sowie ausgewählte Ergebnisse aus der Anwendung des entwickelten Ansatzes dargelegt. Die Messungen vom 01.02.2006 00:00 Uhr bis 31.05.2006 24:00 Uhr (4 Monate bzw. 2880 Stunden) wurden mit Hilfe der IIM-Softwareapplikation hinsichtlich der verursachenden Verkehrslasten analysiert. Aufgrund der hohen Abtastraten wurden insgesamt 157 GByte Messdaten erfasst, wovon etwa 56 GByte im Messdatenanalyseverfahren behandelt wurden. 775401 Fahrzeuge mit einem Gesamtgewicht größer 5 t wurden identifiziert.

### 6.1.2 Voraussetzungen

Zu Kontroll- und Vergleichszwecken wurden am Bauwerk wiederholt Silhouettenzählungen vorgenommen. Die Erhebungen wurden in den Jahren 2005 und 2006 an ausgewählten Werktagen in der Zeit zwischen 11:00 Uhr und 16:30 Uhr durchgeführt und umfassten insgesamt 12 Stunden mit 5540 festgestellten Fahrzeugen. Im genannten Tageszeitraum war die Brücke in besonderem Maße stark befahren.

Aufgrund der verkehrlichen Gegebenheiten (99,6 % der Schwerfahrzeuge wurden auf der rechten Fahrspur beobachtet) erfolgte die automatisierte Analyse der kontinuierlich erfassten Tragwerksreaktionen ausschließlich für den Verkehr der rechten Spur.


## 6.2 Numerisches Rechenmodell

### 6.2.1 Voruntersuchungen, Belastungsversuche

Zur Ermittlung des tatsächlich vorhandenen Beanspruchungsniveaus des Messquerschnitts wurden vorab im Rahmen einer Stabwerksbetrachtung linear elastisch die Schnittgrößen infolge von ständigen Lasten und Temperatur berechnet. Grundlage der

Berechnungen waren die Angaben der Bestandsstatik und der Ausführungsunterlagen. Die Temperatureinwirkungen wurden gemäß DIN-Fachbericht (FB) 101:2003-03 angesetzt. Infolge von Eigen- und Ausbaulasten (59468 kNm), des statisch unbestimmten Anteils der Vorspannung (14011 kNm) sowie eines positiven Temperaturgradienten von 10 K (27083 kNm) wurde unter Annahme des ungerissenen Zustands ein Grundmoment  $M_0$  des Querschnitts von 100,6 MNm ermittelt.

Die Abbildung 6.2 stellt für den instrumentierten Querschnitt den Zusammenhang zwischen Momententragfähigkeit  $M$  und Spannstahldehnungen  $\varepsilon_p$  der Stellen  $\Delta\varepsilon_{m,1}$  bzw.  $\Delta\varepsilon_{m,2}$  dar. Im Rahmen der Querschnittsbetrachtung wurde das Dekompressionsmoment zu 128 MNm bestimmt. Die rechnerische Steigung im ungerissenen Zustand beträgt  $m^I = 3,049 \cdot 10^8$  kNm, wohingegen der ausgeprägt gerissene Zustand eine Steigung von  $m^{II} = 0,496 \cdot 10^8$  kNm aufweist. Zur Verdeutlichung der Auswirkungen einer realistischen Verkehrsbelastung auf die Spannstahldehnungsänderungen wurden ausgehend von  $M_0$  das maximale ( $\max M_{44t} = 5525$  kNm) und minimale ( $\min M_{44t} = -990$  kNm) Moment infolge der 44 t-Fahrzeugkombination gemäß Allgemeinen Rundschreiben Straßenbau 13/2004 vom 18. Mai 2004 angetragen. Die Schnittgröße  $\max M_{44t}$  wurde hierbei unter Berücksichtigung einer Querverteilung der Lasten nach [MeHi06] ermittelt. Es ist zu erkennen, dass der Querschnitt auch bei Ansatz einer ausgesprochen hohen Temperaturbeanspruchung unter realistischen Verkehrslasten im Zustand I verbleibt. Ursache hierfür ist die hohe zentrische Vorspannung des Bauwerks.



**Abbildung 6.2:** Querschnittsbetrachtung: Vorliegendes Beanspruchungsniveau


Zur zweifelsfreien Feststellung der vorliegenden Grundbeanspruchung sowie zur Kalibrierung der Anlage wurden am Bauwerk Probelastungen mit Hilfe von Belastungsfahrzeugen durchgeführt. Um Einflüsse zusätzlicher Einwirkungen auf die Messergeb-

nisse der Versuche zu minimieren, wurde die rechte Spur („Lkw-Spur“) gesperrt. Entsprechend Abbildung 6.1 fuhren die Fahrzeuge von  $x = 0$  m bis 189,88 m. In den Viertelpunkten der drei Felder wurden die Fahrzeuge jeweils angehalten und verweilten eine ausreichende Dauer (3 bis 5 min), so dass zu einem Messzeitpunkt am instrumentierten Querschnitt Dehnungen erfasst wurden, die frei von Verkehrslasten der linken Spur waren. Über dem Messquerschnitt hielten die Fahrzeuge mit jeder Achse an.

Insgesamt wurden 2 Versuche vorgenommen. Zum ersten Versuch wurden bei mäßigem Temperaturgradienten ein 3-achsiger Lastkraftwagen (Lkw) mit einem Gesamtgewicht  $G$  von 32,45 t und ein 5-achsiger Sattelzug ( $G = 40,55$  t) eingesetzt. Der zweite Versuch fand etwa ein halbes Jahr später bei hohem Temperaturgradienten mit einem 3-achsigen Lkw ( $G = 28,95$  t) statt. Die Fahrzeuge überfuhren das Bauwerk jeweils zweimal. Die Tabelle 6.1 enthält eine Übersicht zu den Belastungsversuchen. Die Lastbilder der Fahrzeuge sind dem Anhang B, Abbildung B.10 zu entnehmen.

**Tabelle 6.1:** Belastungsversuche zur Kalibrierung

Datum	Uhrzeit	Fahrzeug	$T_{m,1o}$	$T_{m,1u}$	$T_{m,2o}$	$T_{m,2u}$
[-]	[Uhr]	[-]	[°C]	[°C]	[°C]	[°C]
22.10.2004	10:00 - 11:00	3-achsiger Lkw (32,45 t)	12,0	11,1	12,2	11,3
	11:00 - 12:15	5-achsiger Sattelzug (40,55 t)				
20.06.2005	17:30 - 18:10	3-achsiger Lkw (28,95 t)	31,9	26,5	26,0	24,5




**Abbildung 6.3:** Dehnungen  $\Delta\epsilon_{m,1}$  und  $\Delta\epsilon_{m,2}$ : a) 3-achsiger Lkw, 22.10.2004 ab 10:00 Uhr und b) 3-achsiger Lkw, 20.06.2005 ab 17:45 Uhr

Die Abbildung 6.3 zeigt Dehnungsaufzeichnungen zur Überfahrt der 3-achsigen Lastkraftwagen. Da ausschließlich die Messergebnisse der einzelnen Laststellungen verwendet wurden, sind die Verläufe „kantig“. Es ist zu erkennen, dass die beiden Fahrzeuge bei ähnlichem Gesamtgewicht jedoch stark unterschiedlicher Temperaturbean-

spruchung des Querschnitts dem Betrag nach nahezu gleiche Dehnungen  $\Delta\varepsilon_{m,1}$  und  $\Delta\varepsilon_{m,2}$  hervorriefen. Die Querverteilung der Lasten stellt sich deutlich anhand der Verläufe für  $\Delta\varepsilon_{m,1}$  und  $\Delta\varepsilon_{m,2}$  dar: Befand sich das Fahrzeug bezogen auf den Messquerschnitt im vorherigen bzw. im nachfolgenden Feld, so wurden die beiden Stege gleichermaßen beansprucht ( $\Delta\varepsilon_{m,1} = \Delta\varepsilon_{m,2}$ ); hier hingegen beteiligte sich bei Anordnung des Fahrzeugs über dem Messquerschnitt der Steg, welcher der Last zugewandt war ( $\Delta\varepsilon_{m,1}$ ), etwa zu 61 % am Lastabtrag.

In der Abbildung 6.4 sind die zur jeweiligen Laststellung zugehörigen Momente  $\Delta M_{BF}$  infolge der Belastungsfahrzeuge über die gemessenen Dehnungen  $\Delta\varepsilon_{m,1}$  aufgetragen. Die Momente  $\Delta M_{BF}$  wurden am Stabwerk für den Ort des instrumentierten Querschnitts ermittelt. Die messtechnisch erfasste Querverteilung der Lasten wurde in der Berechnung der Werte  $\Delta M_{BF}$  berücksichtigt. Die Abbildung beruht auf den durchgeführten 6 Belastungsfahrten, welche zu zwei unterschiedlichen Messterminen bei geringer und bei hoher Temperaturbeanspruchung vorgenommen wurden. Die rechnerisch ermittelte Steigung im ungerissenen Zustand wird durch die Messungen bestätigt und kann der Abbildung entnommen werden. Der Zusammenhang zwischen Schnittgrößen bzw. Spannungen und Dehnungen lässt sich demnach linear beschreiben.



**Abbildung 6.4:** Berechnete Momente aufgetragen über gemessene Dehnungen


## 6.2.2 Detailbetrachtungen, wirklichkeitsnahe Modellbildung

Aufbauend auf den erhaltenen Ergebnissen wurde das Tragsystem wirklichkeitsnah in einem Finite Elemente (FE) Programmsystem abgebildet. Zur Minimierung der Rechenzeiten wurden das Feld des instrumentierten Querschnitts sowie die beiden benachbarten Felder dreidimensional mit Hilfe von schwerachsenbezogenen Schalenelementen

modelliert. Die restlichen Felder wurden mit Balkenelementen abgebildet und an die dreidimensionale Modellierung gekoppelt. Im Bereich der Sensororte wurde eine Netzverdichtung vorgenommen. Anhand der Messergebnisse der Belastungsversuche (vgl. Tabelle 6.1) wurde das System kalibriert. Im Rahmen von verifizierenden Berechnungen auf Grundlage von DIN-FB 101:2003-03 und DIN-FB 102:2003-03 konnte der ungerissene Zustand auch für Feld- und Stützquerschnitte der zum Messquerschnitt benachbarten Felder nachgewiesen werden. Die Abbildungen B.1 bis B.5 des Anhangs B zeigen das FE-Modell.

Im Rahmen einer dynamischen Systemanalyse wurden die ersten beiden Eigenfrequenzen der vertikalen Biegeschwingung zu 2,14 Hz und 2,97 Hz bestimmt. Messtechnisch wurden diese zu 2,26 Hz und 3,02 Hz ermittelt. Aufgenommene Frequenzbänder der einzelnen Sensoren sind den Abbildungen B.6 bis B.9 des Anhangs B zu entnehmen. Im Rahmen der Datenvorbereitung wurden mit Hilfe der Softwareapplikation PreProc derartige Einflüsse digital gefiltert und entfernt.


Da der ungerissene Zustand vorliegt, erfolgte die Messdatenanalyse durch die Auswertung von berechneten Einflusslinien und -flächen. Die Abbildung 6.5 zeigt exemplarisch die zum Sensorort  $\Delta \varepsilon_{m,3}$  berechneten Dehnungen (Index „c“)  $\Delta \varepsilon_{c,3}$  für eine Achslast von 1 t in Abhängigkeit von der Laststellung  $x$  und dem Querabstand  $a$  der rechten Radreihe zum Sensor. Die Koordinaten  $x$  und  $a$  sind der Abbildung 6.1 zu entnehmen. Die Auswertung der Einflussflächen erfolgte für die Achsbreite von 2,00 m und eine Radaufstandsfläche von 25x25 cm.



**Abbildung 6.5:** Lokale Dehnungen  $\Delta \varepsilon_{c,3}$  für eine Achslast von 1 t

Bezüglich des Ansatzes eines realistischen statischen Radaufstands wurden vergleichende Berechnungen unter Variation zu erwartender Achslasten und Reifeninnendrucke der Schwerfahrzeuge angestellt. Die Fläche von 25x25 cm wurde als das geeignete Maß festgestellt, um den Radaufstand realer Schwerfahrzeuge abzubilden. Der DIN-FB 101 sieht eine Aufstandsfläche von 40x40 cm vor. Die Achslasten der theoretischen Lastmodelle betragen jedoch ohne Berücksichtigung der Anpassungsfaktoren bis zu 30 t, was in der Realität nicht zu erwarten ist. Zudem gilt der DIN-FB 101 für den Neubau und nicht für die Nachrechnung von bestehenden Bauwerken.

Zur Abschätzung des Fehlers eines unzutreffenden Radaufstands zeigt die Abbildung 6.6 berechnete lokale Plattenreaktionen  $\Delta\epsilon_{c,3}$  für die Flächen 10x10 cm, 25x25 cm und 40x40 cm für Werte  $a = -0,50$  m und  $a = 0,00$  m. Bezogen auf Abbildung 6.5 enthält Abbildung 6.6 demnach Schnitte für zwei gegebene Werte des Querabstands  $a$  der rechten Radreihe. Losgelöst von den bisherigen Erläuterungen ist zu erkennen, dass die Radaufstandsfläche die lokalen Tragwerksreaktionen lediglich für Lasten in der unmittelbaren Nähe zum Sensor beeinflusst. In Längsrichtung besteht ab einem Abstand  $|x'| \geq 0,30$  m kein signifikanter Unterschied zwischen den drei betrachteten Radaufständen. In Querrichtung sind die Dehnungsverläufe ab  $|a| \geq 0,50$  m annähernd deckungsgleich. Da zur Analyse der erfassten lokalen Reaktionen Zeitbereiche betrachtet werden, die die Messung zur Überfahrt eines Fahrzeugs beinhalten, konzentriert sich die Messdatenanalyse keinesfalls auf die Maximalwerte infolge der Achslasten. Die Bedeutung des Radaufstands wird hierdurch nochmals deutlich abgemindert.



**Abbildung 6.6:** Dehnungen  $\Delta\epsilon_{c,3}$  für Radaufstandsflächen 10x10 cm, 25x25 cm und 40x40 cm bei einem Querabstand  $a$  von a) -0,50 m und b) 0,00 m



### 6.3 Genauigkeitsklassifikation

Die Genauigkeit einer Anlage zur Ermittlung von Verkehrslasten unter regulären Verkehrsbedingungen ist von mehreren Faktoren abhängig. Insbesondere Messungenauigkeiten und -toleranzen sowie dynamische Effekte der Fahrzeug-Fahrbahn-Interaktion schlagen sich als Fehler auf die Lastmessung nieder und beeinflussen die erzielbare Genauigkeit der gesuchten statischen Gewichte. Zur einheitlichen Genauigkeitsbewertung der Systeme wurden auf Initiative von FEHRL (Forum of European National Highway Research Laboratories) im Rahmen der COST (Cooperation in Science and Technology) Aktion 323 [COST99] entsprechende Spezifikationen erarbeitet. Diese sehen den Vergleich von automatisiert ermittelten mit den jeweils statisch gewogenen Gewichten vor. Im Rahmen eines statistischen Prüfverfahrens werden die relativen Messfehler der ermittelten zu den bekannten Gewichten bewertet. Zur Kenntnis der statischen Gewichte werden üblicherweise an der Messeinrichtung Prüffahrten mit Belastungsfahrzeugen, die am regulären Verkehrsfluss teilnehmen, durchgeführt. Die Wiegegenauigkeit einer Anlage wird durch die Angabe von Genauigkeitsklassen für die Messgrößen „Gesamtgewichte“ und „Achslasten“ beschrieben. Für die Achslasten wird nochmals eine Differenzierung nach Lasten der Einzelachsen, der Achsgruppen und Achsen der Achsgruppen vorgenommen. Im Grundsatz unterscheiden die COST 323-Spezifikationen 6 Klassen von A(5) bis D(25). Hierbei repräsentiert die Klasse A(5) die höchsten Genauigkeitsanforderungen.

Die Genauigkeitsklassifikation der Anlage wurde entsprechend der COST 323-Spezifikationen durchgeführt. Gemäß Tabelle 6.2 wurden zwei Belastungsfahrzeuge eingesetzt. Die Fahrzeuge überfuhren die Messeinrichtung jeweils 10-mal bei gleicher Geschwindigkeit, unverändertem Gewicht und gleicher seitlicher Position. Die Lastbilder der Fahrzeuge können der Abbildung B.10 des Anhangs B entnommen werden.

**Tabelle 6.2:** Belastungsversuche zur Genauigkeitsbewertung

Datum	Uhrzeit	Fahrzeug	Anzahl der Fahrten
[-]	[Uhr]	[-]	[-]
26.04.2006	11:00 - 14:15	5-achsiger Sattelzug (41,55 t)	10
	13:45 - 16:00	3-achsiger Lastkraftwagen (30,11 t)	10

Für das Kriterium Gesamtgewicht wurde die Klasse A(5) erhalten. Entsprechend der COST 323-Empfehlungen weist diese Klasse eine derart hohe Genauigkeit auf, dass unmittelbar die Strafverfolgung von überladenen Fahrzeugen durchgesetzt werden könnte. Die entwickelte Anlage hätte somit zur Überwachung der Einhaltung von ge-


setzlich zulässigen Fahrzeugesamtgewichten verwendet werden können. Für die Einzelachsen wurde die Klasse C(15) erreicht. Gewichte dieser Klasse sind ausreichend genau, um statistischen Untersuchungen und Ermüdungsbetrachtungen zu Grunde gelegt zu werden. Für die Gewichte der Achsgruppen und Achsen der Achsgruppen wurden jeweils die Genauigkeiten B(10) erzielt. Gewichte der Klasse B(10) weisen eine hohe Genauigkeit auf. Zur Strafverfolgung von überladenen Fahrzeugen kann ein derartiges System zur effizienten Vorauswahl von überladenen Fahrzeugen dienen.

Entsprechend der COST 323-Spezifikationen wurden mit Hilfe der eigenen Entwicklungen in den betrachteten Gewichtskriterien hohe bis sehr hohe Genauigkeiten erzielt.

## 6.4 Ergebnisse der Verkehrslastermittlung

Nachfolgend werden beispielhaft ausgewählte Ergebnisse der Messdatenanalyse dargestellt. Die Ergebnisse dienen der Illustration und sollen das Potential des vorgeschlagenen Ansatzes aufzeigen.

Im Rahmen von Silhouettenerhebungen in der Zeit zwischen 11:00 Uhr und 16:30 Uhr über 12 Stunden an verschiedenen Werktagen wurde der 5-achsige Sattelzug mit 2 Achsen im Bereich der Zugmaschine und 3 Achsen im Bereich des Aufliegers am Bauwerk mit einer Häufigkeit  $p$  von 60 % angetroffen. Bei 10 % der Sattelzüge wurde mindestens eine geliftete Achse beobachtet (siehe Abbildung 6.7). Die Liftachsen werden bei Leerfahrten zur Schonung von Bremsbelägen und Bereifung angehoben.




**Abbildung 6.7:** Ergebnisse der Silhouettenerhebungen (12 Stunden, 5540 Fahrzeuge)

Bei Verkehrszählungen in Hamburg [NBBP07] bzw. in Essen [BuSL07] beschrieben Sattelzüge über 80 % bzw. über 50 % des Schwerverkehrsaufkommens.

In der automatisierten Messdatenauswertung werden die Fahrzeuge nach der Anzahl der Achsen auf der Fahrbahn festgestellt. Den Ergebnissen der Silhouettenerhebungen entsprechend wurde der 5-achsige Sattelzug in der Analyse der Messdaten, die über 4 Monate kontinuierlich aufgenommen wurden, mit einer Häufigkeit von 44 % erfasst. Insgesamt wurden im betrachteten Zeitraum 775401 Fahrzeuge mit einem Gesamtgewicht von mehr als 5 t identifiziert, wovon 336926 Fahrzeuge 5-achsige Sattelzüge darstellten. Hiernach kommt dem 5-achsigen Sattelzug eine ausgesprochen hohe Bedeutung zu; er kann als in besonderem Maße repräsentativ für das Verkehrsaufkommen bezeichnet werden. Im Folgenden werden Detailergebnisse für diesen Fahrzeugtyp präsentiert.

Die Abbildung 6.8 zeigt die Häufigkeitsverteilung der Fahrzeuggesamtwichte  $Q_{\text{tot}}$ . Gemäß Straßenverkehrszulassungsordnung beträgt das zulässige Gesamtgewicht für die Fahrzeuge 40 t. Ein Anteil von 18 % der Sattelzüge wurde als „überladen“ identifiziert. Hierbei ist zu beachten, dass Leerfahrten aufgrund von angehobenen Achsen teilweise als 4- bzw. 3-achsige Fahrzeuge aufgenommen wurden und in der gezeigten Häufigkeitsverteilung nicht enthalten sind. Unter Berücksichtigung der Leerfahrten für die Silhouette des 5-achsigen Sattelzugs würde sich der prozentuale Anteil der überladenen Fahrzeuge vermindern. Das höchste Gesamtgewicht wurde mit 67,7 t festgestellt.



**Abbildung 6.8:** 5-achsige Sattelzüge: Häufigkeitsverteilung der Gesamtgewichte

Die Abbildungen 6.9 bis 6.11 zeigen die aufgenommen Achslasten über dem jeweils zugehörigen Fahrzeuggesamtwicht. In der Tendenz wurden ähnliche Ergebnisse anlässlich der Messungen „Achslastdaten 1998“ [BASt98] festgestellt. Aufgrund der vorhandenen Korrelation zwischen den beiden Größen wurde eine lineare Regression vorgenommen. Die höchste beobachtete Achslast betrug  $Q_2 = 17,3$  t.




Abbildung 6.9: 5-achsige Sattelzüge: Achslast der 1. Achse




Abbildung 6.10: 5-achsige Sattelzüge: Achslast der 2. Achse




Abbildung 6.11: 5-achsige Sattelzüge: Mittlere Achslast der Tripelachse

Ausführliche Ergebnisse der Messdatenanalyse können dem Forschungsbericht [BuSL07], der im Rahmen des durch das Bundesministerium für Verkehr, Bau und Stadtentwicklung (BMVBS) beauftragten und durch die Bundesanstalt für Straßenwesen (BASt) betreuten Forschungs- und Entwicklungsvorhabens 15.0388/2003/GRB entstand, entnommen werden.

## Kapitel 7

# Zusammenfassung und Ausblick

### 7.1 Zusammenfassung

In der vorliegenden Arbeit wurde der IIM (Identification-in-Motion) Algorithmus zur Identifikation von Verkehrslasten entwickelt und prototypisch implementiert. Der Ansatz berücksichtigt die Analyse von statischen Tragwerksreaktionen, die kontinuierlich an entsprechend instrumentierten Brückenüberbauten erfasst werden. Einzelne Fahrzeuge werden hierbei aus Messdaten identifiziert, die während der Anwesenheit eines einzelnen oder mehrerer Fahrzeuge auf der Brücke aufgezeichnet wurden. Für die Fahrzeuge werden die Attribute Auftretenszeitpunkt, Gesamtgewicht, Geschwindigkeit, Achslasten und -abstände ermittelt. Zur Messung können konventionelle Dehnungsmessstreifen oder wieder verwendbare Wegaufnehmer eingesetzt werden. Aufgrund der Analyse von Bauwerksmessungen kann die Methodik in Kombination mit Monitoringssystemen, die gleichermaßen Messungen erfordern, eingesetzt werden.

Anhand von numerischen Untersuchungen wurden die Tragwerksreaktionen festgestellt, welche maßgeblich auf die einwirkenden Lasten schließen lassen. Durch die Unterscheidung von globalen und lokalen Reaktionen wird die Anzahl der erforderlichen Messelemente minimiert. Sowohl praxisrelevante Anforderungen hinsichtlich der Wirtschaftlichkeit des Verfahrens sowie des Installations- und Wartungsaufwands als auch Anforderungen bezüglich der Effizienz der Messdatenanalyse werden hierdurch erfüllt.

Die Problemstellung wird im Rahmen einer modellbasierten Lastidentifikation gelöst: Unter Verwendung des zum inversen Problem zugehörigen Vorwärtzlösers, in aller Regel ein Finite Elemente Berechnungskern, werden parametrisierte Rechenmodelle iterativ auf am Bauwerk erfasste Messgrößen angepasst. Die Lastkomponente der Modelle beschreibt die zum jeweiligen Messzeitpunkt vorliegende Belastungssituation und er-

möglicht die Feststellung der einzelnen Fahrzeuge. Die Analyse von kontinuierlich erfassten Tragwerksreaktionen erfolgt in Zeitschritten durch die Betrachtung eines jeweils zugehörigen Zeitintervalls. Der Unterscheidung nach globalen und lokalen Reaktionen entsprechend wird die Lastidentifikation im Rahmen von zwei gekapselten Optimierungskernen durchgeführt. Je Reaktionsart werden definierte Fahrzeugattribute festgestellt: Globale Reaktionen dienen zur Bestimmung von übergeordneten Fahrzeugkennwerten, lokale Reaktionen werden zur Ermittlung der Achseigenschaften der Fahrzeuge herangezogen. In dieser direkten Unterscheidung tragen die beiden Reaktionstypen jeweils bestmöglich zur Feststellung der Fahrzeugattribute bei, der Suchraum der Problemstellung wird minimiert und die Gesamteffizienz des Algorithmus wird gesteigert. Im jeweiligen Optimierungsprozess wird im Wesentlichen die Minimierung der Fehlerquadratsumme aus gemessenen und berechneten Tragwerksreaktionen behandelt. Die Zielfunktionen der kleinsten Fehlerquadrate gewährleisten die Robustheit gegenüber teilweise verrauschten und ungenauen Messwerten. Der Ansatz berücksichtigt die isolierte Verwendung des Vorwärtslösers. Hierdurch wird die Gültigkeit sowohl für lineare als auch für nichtlineare Systeme sichergestellt. Die Lastidentifikation im Rahmen einer Modelladaption hat sich zur Problemlösung als überaus gut geeignet erwiesen.

Zur Lösung der Optimierungsprobleme wurden Verfahren auf Basis der Genetischen Programmierung (GP) untersucht und entwickelt. Die GP zählt zur Gruppe der Evolutionären Algorithmen (EA), die sich in zahlreichen Anwendungen zur Ermittlung der globalen Extrema von Zielfunktionen als sehr günstig erwiesen haben. Im Vergleich zu anderen EA-Dialekten besitzt die GP eine ausgesprochen hohe Flexibilität und Variabilität in der Repräsentation der Lösungskandidaten. Die GP ist daher zur Lösung von komplexen Optimierungsaufgaben prädestiniert. Zur Analyse von kontinuierlich erfassten Tragwerksreaktionen werden die in [PuSL07] eingeführten wahrscheinlichkeitsorientierten Operatoren im Vorgehen berücksichtigt. Die Operatoren ermöglichen für die GP eine zielgerichtete Initialisierung und Mutation. Sie haben sich als extrem leistungsstarke Hilfsmittel zur Aufnahme von Domänenwissen im Optimierungsprozess erwiesen. Zur Erzielung eines günstigen Lösungsverhaltens werden evolutionäre Parameter, wie die Populationsgröße, Rekombinations- und Mutationswahrscheinlichkeiten, in den GP-Optimierungsprozessen deterministisch angepasst. Geeignete Werte für die Parameter wurden im Rahmen einer umfangreichen Evaluierung ermittelt. Zur Reduzierung des Optimierungsaufwands werden künstliche Neuronale Netze hybrid in das GP-Analyseverfahren der lokalen Reaktionen eingebunden. Aufgrund ihrer hohen Lern- und Generalisierungsfähigkeit wurden mehrschichtige feedforward Systeme (Multi-

layer-Perceptrons) gewählt. Mit ihrer Hilfe werden in einer vergleichsweise einfachen Mustererkennung die Auftretenszeitpunkte der Achsen abgeschätzt und als Initialwerte der GP-Optimierung gesetzt. In umfangreichen Parameterstudien haben die mehrschichtigen Netzwerke eine sehr gute Performanz in der Analyse von realen Messwerten gezeigt. Im Rahmen der Untersuchungen wurden auch verschmierte Messsignale sehr geringer Amplituden betrachtet und zuverlässig analysiert. Die Genetische Programmierung und die hybrid integrierten Neuronalen Netze haben sich als probate Mittel zur Lösung der gegebenen komplexen Problemstellung gezeigt.

Um die entwickelten Methoden zu verifizieren und deren Eignung zu demonstrieren, wurde der IIM-Algorithmus prototypisch implementiert. Zur Vorhaltung und Aufbereitung von kontinuierlich erfassten Messdaten entstand zudem die Softwareapplikation PreProc. Zur Nachbereitung und Interpretation von gewonnenen Ergebnissen wurde die Applikation PostProc entwickelt. Die eigenen Entwicklungen wurden objektorientiert in der Programmiersprache C++ umgesetzt.

Das entstandene Softwarepaket wurde zur Analyse von Messdaten, die im Rahmen einer Dauermessung über 4 Monate an einem repräsentativen Brückenbauwerk gewonnen wurden, eingesetzt. Insgesamt wurden 775401 einzelne Fahrzeuge zuverlässig identifiziert. Das hohe Potential des vorgeschlagenen Ansatzes wurde aufgezeigt und dessen Eignung anhand einer realen Anwendung bestätigt. Die Bewertung gemäß den COST 323-Empfehlungen ließ erkennen, dass mit der Anwendung des Verfahrens außerordentlich genaue Ergebnisse erhalten werden können.

## 7.2 Ausblick

In der automatisierten Messdatenauswertung werden die Schwerfahrzeuge nach der Anzahl der Achsen auf der Fahrbahn festgestellt. Aufgrund von Liftachsen, die zu Leerfahrten angehoben werden (vgl. Kapitel 6.5), kann der tatsächliche Fahrzeugtyp nur eingeschränkt bestimmt werden. Sowohl zur Angabe der wirklichen Auftretenshäufigkeiten der einzelnen Fahrzeugtypen als auch zur gezielten Zuweisung der ermittelten Gewichte ist die Kenntnis der Fahrzeugsilhouetten von hoher Bedeutung. In zukünftigen Arbeiten sollte zum Erhalt der Silhouetten die Ergänzung des Ansatzes um eine automatisierte Videoanalyse untersucht werden (siehe beispielsweise [AcTr04] und [AlAb06]). Die Kenntnis der Fahrzeuggewichte und der -silhouetten könnte unter anderem zur genauen Definition von realitätsnahen Ermüdungslastmodellen verwendet werden.

Die entstandenen Softwareapplikationen wurden zur Analyse von Querschnittsdehnungen, die am Überbau einer Betonbrücke aufgezeichnet wurden, eingesetzt. Im Rahmen weiterer Arbeiten könnten die entwickelten Methoden auf Bauwerke mit anderen Querschnittsformen und statischen Systemen, die ggf. auch eine andere Konstruktion (beispielsweise Bauwerke der Stahl- oder Stahlverbundbauweise) aufweisen, angewandt werden. Von Interesse wäre auch die Verifizierung des Ansatzes anhand eines Bauwerks mit ausgeprägt physikalisch nichtlinearem Verhalten. Es wäre zu untersuchen, ob die erreichten hohen Genauigkeitsklassen auch hier erzielt werden können und ob der sich einstellende Rechenaufwand in der realen Anwendung praktikabel ist.

In weiterführenden Arbeiten könnte zudem die Verallgemeinerung bzw. die Übertragung der Entwicklungen auf das Gebiet der Nutzlastermittlung bei Tragwerken des allgemeinen Hochbaus betrachtet werden. Denkbar wäre der Erhalt von realistischen Wind- und Schneelasten im Rahmen einer kontinuierlichen Bauwerksmessung.

Die Erweiterung der entwickelten Methoden auf das Gebiet des Bauwerksmonitorings stellt einen zusätzlichen vielversprechenden Ansatz dar. Die Zusammenführung der Lastidentifikation des IIM-Algorithmus mit Methoden der Systemidentifikation könnte in einer kontinuierlichen Bauwerksüberwachung zusätzlich zum Erhalt der effektiv einwirkenden Lasten die automatisierte und frühzeitige Schadensdetektion ermöglichen. Im Rahmen einer Modelladaption wären hierzu Kennwerte der Last- und Systemkomponente von parametrisierten Rechenmodellen auf am Bauwerk erfasste Tragwerksreaktionen anzupassen (vgl. Gleichung 1.1). Zur realitätsnahen Adaption der Modelle sollten physikalisch nichtlineare Finite Elemente Berechnungen unter Betrachtung von diskreten, direkt interpretierbaren Schadenskenngößen durchgeführt werden. Adaptierte Modelle würden den Tragwerkszustand zum jeweiligen Messzeitpunkt repräsentieren. Die Schadensdiagnose könnte durch den Vergleich identifizierter Systemkomponenten verschiedener Messzeitpunkte erfolgen: Änderungen in den diskreten Schadenskenngößen würden die Feststellung von Schadensort, -art und -ausmaß ermöglichen. Aufgrund der höheren Sensitivität sollten statische Tragwerksreaktionen den Untersuchungen zu Grunde gelegt werden (vgl. Kapitel 1.2.3). Zur Modelladaption könnte ein auf Genetischer Programmierung basierendes Optimierungsverfahren unter Berücksichtigung der Ausführungen hinsichtlich der Verwendung von wahrscheinlichkeitsorientierten Operatoren (vgl. Kapitel 2.2.4) sowie der Adaption von evolutionären Parametern (vgl. Kapitel 5.1) verwendet werden.



## **Anhang A**

### **Berechnungsbeispiel**




Abbildung A.1: Finite Elemente (FE) Modell





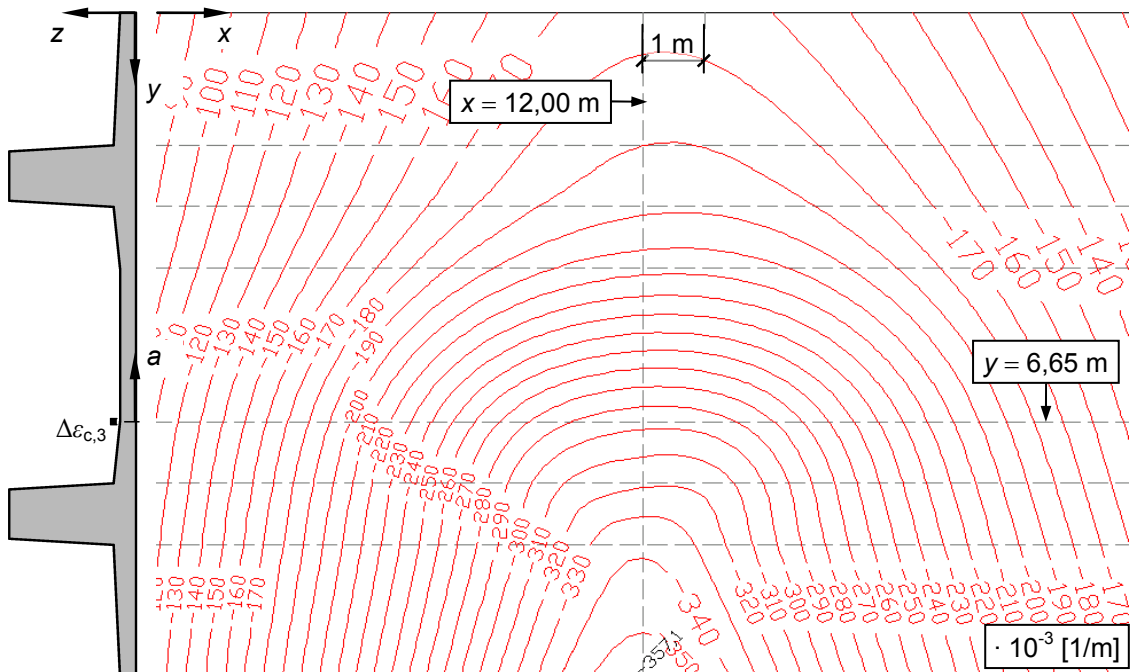
Abbildung A.2: Überbau-Querschnitt einschließlich der betrachteten Stellen

Tabelle A.1: Belastung


Nr.	Bezeichnung	Geometrie und Achslasten
1	5-achsiger Sattelzug	→ Belastungsfahrzeuge vom 22.10.2004, Anhang B
2	3-achsiger Lastkraftwagen	
Zur Berechnung wurde die Radaufstandfläche mit 40x40 cm gemäß DIN-Fachbericht 101:2003-03, IV-4.3 angesetzt. Bei einer Fahrbahnbelagsdicke von 8 cm folgt die rechnerische Lastverteilungsbreite zu $t = 0,40 + 2 \cdot (0,08 + 0,5 \cdot 0,25) = 0,81 \text{ m}$ .		




**Abbildung A.3:** Einflussfläche des Biegemoments  $m_x$  der Fahrbahnplatte bei  $x/y = 12,00/6,65$  m für eine in  $z$ -Richtung wirkende Wanderlast



**Abbildung A.4:** Einflussfläche der Normalkraft  $n_x$  der Fahrbahnplatte bei  $x/y = 12,00/6,65$  m für eine in  $z$ -Richtung wirkende Wanderlast



**Abbildung A.5:** Einflussfläche des Biegemoments  $m_y$  der Fahrbahnplatte bei  $x/y = 12,00/6,65$  m für eine in  $z$ -Richtung wirkende Wanderlast



**Abbildung A.6:** Einflussfläche der Normalkraft  $n_y$  der Fahrbahnplatte bei  $x/y = 12,00/6,65$  m für eine in  $z$ -Richtung wirkende Wanderlast

## **Anhang B**

### **Anwendungsbeispiel**


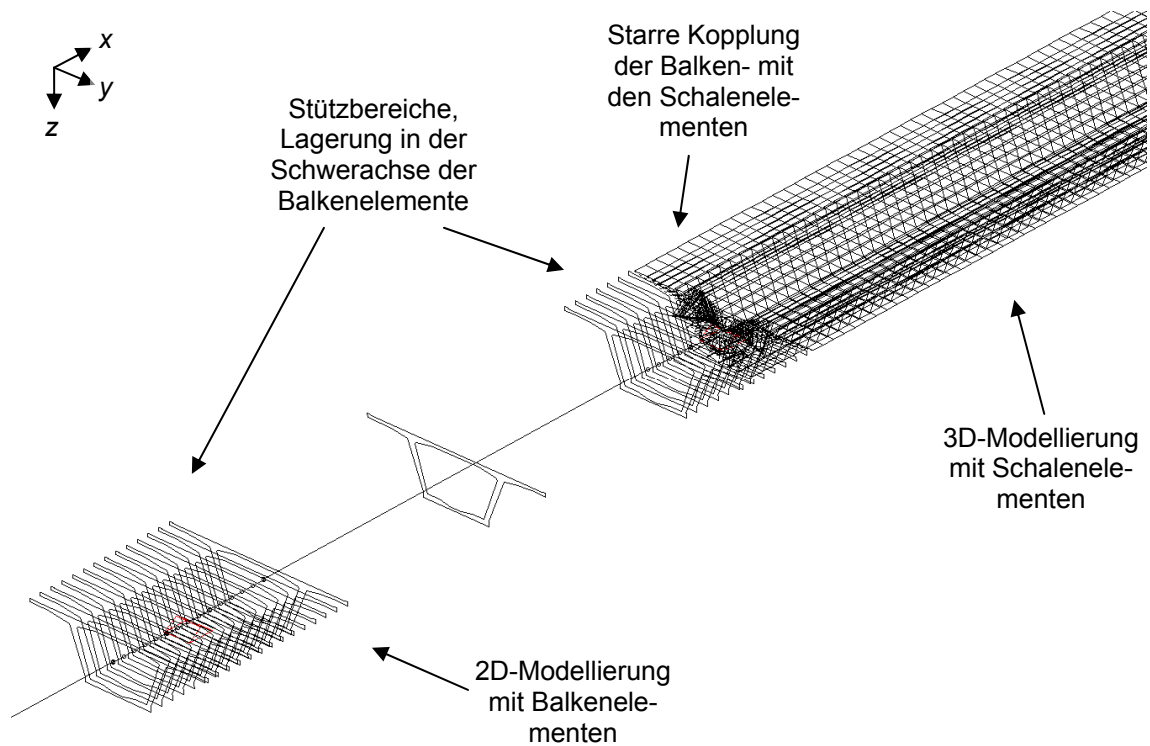




Abbildung B.1: Finite Elemente (FE) Modell




**Abbildung B.2:** Ausschnitt aus dem FE-Modell: Kopplung der Balken- mit den Schalelementen



**Abbildung B.3:** Ausschnitt aus dem FE-Modell: 3D-Modellierung – Netzverdichtung im Bereich des Messquerschnitts



**Abbildung B.4:** Ausschnitt aus dem FE-Modell, transparent gerenderte Draufsicht: Übergang der 2D- zur 3D-Modellierung, Spanngliedführung



**Abbildung B.5:** Ausschnitt aus dem FE-Modell, transparent gerenderte Ansicht: Übergang der 2D- zur 3D-Modellierung, Spanngliedführung






Abbildung B.6: Frequenzband zur Aufzeichnung  $\Delta\varepsilon_{m,1}$




Abbildung B.7: Frequenzband zur Aufzeichnung  $\Delta\varepsilon_{m,2}$




Abbildung B.8: Frequenzband zur Aufzeichnung  $\Delta\varepsilon_{m,3}$




Abbildung B.9: Frequenzband zur Aufzeichnung  $\Delta\varepsilon_{m,4}$

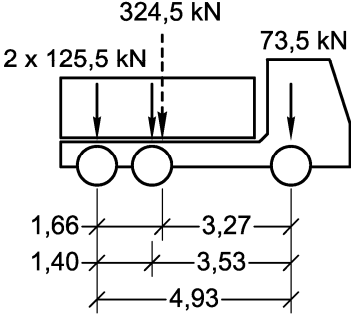
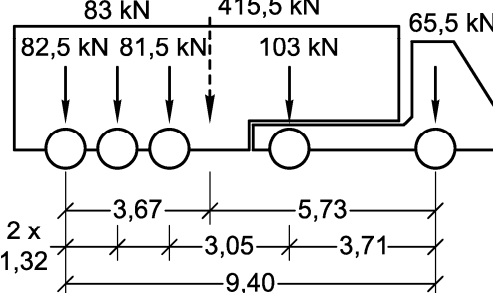
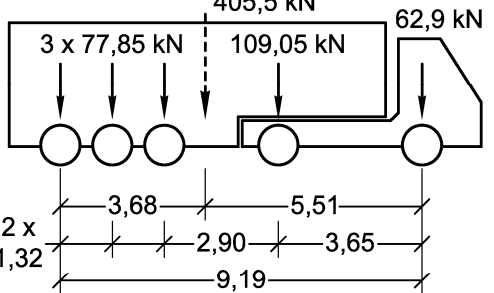
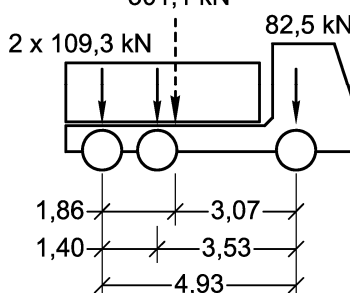
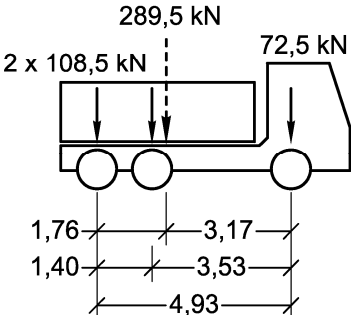
Kalibrierung	Genauigkeitsklassifikation
<p><u>22.10.2004, 3-achsiger Lastkraftwagen</u></p> 	<p><u>26.04.2006, 5-achsiger Sattelzug</u></p> 
<p><u>22.10.2004, 5-achsiger Sattelzug</u></p> 	<p><u>26.04.2006, 3-achsiger Lastkraftwagen</u></p> 
<p><u>20.06.2005, 3-achsiger Lastkraftwagen</u></p> 	

Abbildung B.10: Belastungsfahrzeuge: Kalibrierung und Genauigkeitsklassifikation

## **Anhang C**

### **Boxplot**

## Boxplot

Der Boxplot ist ein Diagramm zur Darstellung der Häufigkeitsverteilung einer Reihe von numerischen Daten. In einer Grafik werden Zentrum, Streuung, Schiefe, Spannweite und Ausreißer der Datenwerte zusammenfasst.

Die „Box“ umfasst die mittleren 50 % der Daten und erstreckt sich vom unteren zum oberen Quartil (25 %- und 75 %-Quantile). Durch die Länge der Box ergibt sich der Interquartilabstand, welcher Aussagen über die Streuung der Daten ermöglicht. Das 50 %-Quantil, der Median, vermittelt durch seine Lage innerhalb der Box einen Eindruck über die den Daten zugrunde liegende Schiefe. Des Weiteren werden die 1%-, 5 %-, 95 %- und 99%-Quantile im Diagramm eingetragen. Zur Bewertung von Ausreißern werden die extremalen Datenwerte kenntlich gemacht. Als weitere Information enthält der Boxplot das arithmetische Mittel der Daten.


In der Abbildung C.1 sind beispielhaft für Daten mit Werten von 17 bis 43 (ohne Einheit) die Häufigkeits- und Normalverteilung sowie der Boxplot gezeigt.

Tabelle (Datenwerte und Ergebnisse)

Klassen- grenzen	Häufigkeiten		Summen	
	n [-]	p [%]	n [-]	p [%]
≥ 43	0	0,0	1001	100,0
41-43	1	0,1	1001	100,0
39-41	4	0,4	1000	99,9
37-39	18	1,8	996	99,5
35-37	55	5,5	978	97,7
33-35	119	11,9	923	92,2
31-33	191	19,1	804	80,3
29-31	225	22,5	613	61,2
27-29	191	19,1	388	38,8
25-27	119	11,9	197	19,7
23-25	55	5,5	78	7,8
21-23	18	1,8	23	2,3
19-21	4	0,4	5	0,5
17-19	1	0,1	1	0,1
< 17	0	0,0	0	0,0

Diagramm

- 1) Häufigkeits- und Normalverteilung  
2) Boxplot



Legende zum Boxplot:




Abbildung C.1: Beispiel: Häufigkeitsverteilung, Normalverteilung und Boxplot

## Literaturverzeichnis

- [AcTr04] Achler, O.; Trivedi, M.M.: Camera Based Vehicle Detection, Tracking, and Wheel Baseline Estimation Approach. Tagungsband '7<sup>th</sup> International IEEE Conference on Intelligent Transportation Systems (ITSC 2004)', Washington DC, 3. bis 6. Oktober, 2004.
- [Adam03] Adamy, J.: Fuzzy Logik, Neuronale Netze und Evolutionäre Algorithmen. Skript zur Vorlesung, TU Darmstadt, 5. Auflage, 2003.
- [AlAb06] Al-Garni, S.M.; Abdennour, A.A.: Moving Vehicles Detection using Automatic Background Extraction. Proceedings of World Academy of Science, Engineering and Technology, Vol. 18, S. 180-184, 2006.
- [Banz01] Banzhaf, W.: Artificial Intelligence: Genetic Programming. Elsevier Encyclopedia of the Social and Behavioral Sciences, 2001.
- [BASt98] Bundesanstalt für Straßenwesen (BASt): Achslastdaten Hessen, Januar bis März 1998, Auswertungen. Bergisch Gladbach, 1998.
- [BBJP03] Beyer, H.-G.; Brucherseifer, E.; Jakob, W.; Pohlheim, H.; Sendhoff, B.; To, T.B.: Evolutionäre Algorithmen – Begriffe und Definitionen. Im VDI/VDE-Handbuch Regelungstechnik, Verein Deutscher Ingenieure, Düsseldorf und Beuth Verlag GmbH, Berlin, 2003.
- [BoBe03] Bolle, G.; Berndt, R.-D.: Innovatives Informationsmanagement bei Monitoring-Untersuchungen. Fachtagung – Sonderkapitel aus dem Brücken- und Ingenieurbau, S. 87-91, Verlag für Wissenschaft GmbH, 2003.
- [Bode04] Bodenhofer, U.: Genetic Algorithms: Theory and Applications. Lecture Notes, Fuzzy Logic Laboratorium Linz-Hagenberg / Österreich, 3. Auflage, 2004.

- [Broc03] Greulich, W. [Red.]: Der Brockhaus Computer und Informationstechnologie. Brockhaus, Mannheim, 2003.
- [BuSL07] Buschmeyer, W.; Schnellenbach-Held, M.; Lubasch, P.: Schwerlastverkehr auf Bundesfernstraßen: Erfassung, Erhaltungsbedarf für Brücken. Forschungsbericht FE-Nr. 15.0388/2003/GRB, Essen, 2007.
- [CaMo05] Caddemi, S.; Morassi, A.: Detecting Damage in a Beam by Static Tests. Tagungsband '6<sup>th</sup> International Conference on Damage Assessment of Structures', Gdansk, Polen, S. 493-500, 2005.
- [ChGh01] Chou, J.H.; Ghaboussi, J.: Genetic Algorithm in Structural Damage Detection. Computers & Structures 79, S. 1335-1353, 2001.
- [COST99] COST323: European Specification on Weigh-in-Motion of Road Vehicles. EUCO COST/323/8/99, LCPC, Paris, 1999.
- [CuLP05] Curbach, M.; Loos, S.; Proske, D.: Anpassungsfaktoren für das Lastmodell 1 des DIN-Fachberichtes 101 für gewichtsbeschränkt beschilderte Straßenbrücken. Beton- und Stahlbetonbau 100, Heft 7, S. 590-598, 2005.
- [Da1859] Darwin, C.: On the Origin of Species. 1859.
- [DCCr90] D'Cruz, J.; Crisp, J.D.C.: Determining a Force Acting on a Plate – An Inverse Problem. AIAA Journal, Vol. 29, No. 3, S. 464-470, 1990.
- [EiHM99] Eiben, A.E.; Hinterding, R.; Michalewicz, Z.: Parameter Control in Evolutionary Algorithms. IEEE Transactions on Evolutionary Computation, IEEE, Vol. 3, No. 2, S. 124-141, 1999.
- [EiSc98] Eiben, A.E.; Schippers, C.A.: On Evolutionary Exploration and Exploitation. Fundamenta Informaticae 35, S. 35-50, 1998.
- [EiSc02] Eiben, A.E.; Schoenauer, M.: Evolutionary Computing. Information Processing Letters 82, S. 1-6, 2002.
- [EiSm03] Eiben, A.E.; Smith, J.E.: Introduction to Evolutionary Computing. Springer-Verlag, Berlin, 2003.
- [FaPS96] Fayyad, U.; Piatetsky-Shapiro, G.; Smyth, P.: From Data Mining to Knowledge Discovery in Databases. AI Magazin, S. 37-54, 1996.

- 
- [FaSR04] Farrar, C.R.; Sohn, H.; Robertson, A.N.: Applications of Nonlinear System Identification to Structural Health Monitoring. Tagungsband '2<sup>nd</sup> European Workshop on Structural Health Monitoring', S. 59-67, München, 2004.
- [Felt02] Feltrin, G.: Temperature and Damage Effects on Modal Parameters of a Reinforced Concrete Bridge. EURODYN, München, 2002.
- [FeTe01] Feiden, D.; Tetzlaff, R.: Iterative Annealing: A new Efficient Optimization Method for Cellular Neural Networks. Proceedings of the 2001 International Conference on Image Processing (ICIP 2001), Thessaloniki, Griechenland, 2001.
- [FFKM96] Frenzel, B.; Freundt, U.; König, G.; Mangerig, I.; Merzenich, G.; Novák, B.; Sedlacek, G.; Sukhov, D.: Bestimmung von Kombinationsbeiwerten und -regeln für Einwirkungen auf Brücken. Forschung Straßenbau und Straßenverkehrstechnik, Heft 715, Bonn, 1996.
- [FoOW66] Fogel, L.J.; Owens, A.J.; Walsh, M.J.: Artificial Intelligence through Simulated Evolution. John Wiley & Sons Inc., New York, 1966.
- [Frit05] Fritzen, C.P.: Vibration-based Structural Health Monitoring – Concepts and Applications. Tagungsband '6<sup>th</sup> International Conference on Damage Assessment of Structures', Gdansk, Polen, S. 3-18, 2005.
- [FrPM92] Frawley, W.J.; Piatetsky-Shapiro, G.; Matheus, C.J.: Knowledge Discovery in Databases: An Overview. AI Magazine, 13, S. 57-70, 1992.
- [GaFA94] Gagarin, N.; Flood, I.; Albrecht, P.: Computing Truck Attributes with Artificial Neural Networks. ASCE, Journal of Computing in Civil Engineering, Vol. 8, No. 2, S. 179-200, 1994.
- [GeFl05] Geier, R.; Flesch, R.: Ein Konzept für integriertes Bauwerksmonitoring. D-A-CH-Mitteilungsblatt, Band 80, September 2005.
- [Geye95] Geyer-Schulz, A.: Fuzzy Rule-based Expert-Systems and Genetic Machine Learning. Physica-Verlag, 1995.
- [GKLR06] Glaeser, K.-P.; Kaschner, R.; Lerner, M.; Roder, K.; Weber, R.; Wolf, A.; Zander, U.: Auswirkungen von neuen Fahrzeugkonzepten auf die Infrastruktur des Bundesfernstraßennetzes. BAST, Bergisch Gladbach, 2006.

- [Gold89] Goldberg, D.E.: Genetic Algorithm in Search, Optimization and Machine Learning. Reading, Addison-Wesley Publishing Company, Inc., Reading, Massachusetts, 1989.
- [Gonz01] Gonzalez, A.: Development of Accurate Methods of Weighing Trucks in Motion. PhD Thesis, Trinity College Dublin, 2001.
- [GrHL07] Grünberg, J.; Hansen, M.; Liebig, J.P.: Ermüdungsbeanspruchungen von Betonbrücken unter zunehmendem Schwerverkehr. Beton- und Stahlbetonbau 102, Heft 9, S. 596-606, 2007.
- [Groe93] Groetsch, C.W.: Inverse Problems in the Mathematical Sciences. ISBN 3-528-06545-1, Vieweg Publishing, Wiesbaden, 1993.
- [HaGr06] Hansen, M.; Grünberg, J.: Überwachungsmaßnahmen und Bauwerkszuverlässigkeit – Zusammenhänge und Auswirkungen. Beton- und Stahlbetonbau 101, Heft 5, S. 343-349, 2006.
- [HCHF06] Huth, O.; Czaderski, C.; Hejll, A.; Feltrin, G.; Motavalli, M.: Tendon Breakages Effect on Static and Modal Parameters of a Post-Tensioned Concrete Girder. Tagungsband der Konferenz ‘The 2<sup>nd</sup> International Conference on Structural Health Monitoring of Intelligent Infrastructure (SHMII-2)’, Shenzhen, China, S. 847-853, 2005.
- [Hebb49] Hebb, D.O.: The Organization of Behavior: A Neuropsychological Theory. Wiley, New York, 1949.
- [HeLV98] Herrera, F.; Lozano, M.; Verdegay, J.L.: Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis. Artificial Intelligence Review, Vol. 12, No. 4, S. 265-319, 1998.
- [HiME97] Hinterding, R.; Michalewicz, Z.; Eiben, A.E.: Adaptation in Evolutionary Computation: A Survey. Proceedings of the 4<sup>th</sup> IEEE International Conference on Evolutionary Computation, Indianapolis, USA, S. 65-69, 1997.
- [HiSa06] Hinton, G.E.; Salakhutdinov, R.R.: Reducing the Dimensionality of Data with Neural Networks. Science, Vol. 313, S. 504-507, 2006.
- [Holl75] Holland, J.H.: Adaptation in Natural and Artificial Systems. Ann Arbor, MI, The University of Michigan Press, ISBN 0262581116, 1975.



- 
- [HWSR07] Hoffmann, S.; Wendner, R.; Strauss, A.; Ralbovsky, M.; Bergmeister, K.: AFIT – Anwenderorientierte Identifikation für Ingenieurtragwerke, Versuchsgestützte Steifigkeitsanalysen. Beton- und Stahlbetonbau 102, Heft 10, S. 699-706, 2007.
- [IRD01] IRD (International Road Dynamics Inc.): Weigh-in-Motion Technology Comparisons. [www.irdinc.com](http://www.irdinc.com), 2001.
- [JaOB05] Jacob, B.; O'Brien, E.J.: Weigh-in-Motion: Recent Developments in Europe. Tagungsband '4<sup>th</sup> International Conference on WIM', ICWIM4, Taipei, S. 2-12, 2005.
- [Koza92] Koza, J.R.: Genetic Programming: On the Programming of Computers by Means of Natural Selection. Cambridge, MA: MIT Press, 1992.
- [Koza94] Koza, J.R.: Genetic Programming II: Automatic Discovery of Reusable Programs. Cambridge, MA: MIT Press, 1994.
- [Link00] Link, M.: Was kann man von rechnerisch auf Testdaten angepassten Finite-Elemente Modellen erwarten? VDI-Schwingungstagung 'Experimentelle und rechnerische Modalanalyse sowie Identifikation dynamischer Systeme', VDI-Berichte 1550, Juni 2000.
- [Lipp05] Lippe, W.M.: Soft-Computing. Springer, 2005.
- [LiRa05] Liszkai, T.R.; Raich, A.M.: Solving Inverse Problems in Structural Damage Identification using Advanced Genetic Algorithm Representations. Tagungsband '6<sup>th</sup> World Congress of Structural and Multidisciplinary Optimization', Rio de Janeiro, Brasilien, 2005.
- [LiRW98] Li, X.; Ruan, D.; Van der Wal, A.J.: Discussion on Soft Computing at FLINS'96. International Journal of Intelligent Systems, 13 (2-3), S. 287-300, 1998.
- [LiXW01] Liu, G.R.; Xu, Y.G.; Wu, Z.P.: Total Solution for Structural Mechanics Problems. Computer Methods in Applied Mechanics and Engineering, 191, S. 989-1012, 2001.
- [LSFB06] Lubasch, P.; Schnellenbach-Held, M.; Freischlad, M.; Buschmeyer, W.: Knowledge Discovery in Bridge Monitoring Data: A Soft Computing Approach. In I.F.C. Smith (Ed.): Intelligent Computing in Engineering and Architecture, Lecture Notes in Artificial Intelligence, Springer Verlag, 2006.

- [LuBa99] Lutzenberger, S.; Baumgärtner, W.: Interaction of an Instrumented Truck Crossing Belleville Bridge. Weigh-in-Motion of Road Vehicles, ed. Jacob, Hermès Science Publications, Paris, 1999.
- [LuBa00] Lutzenberger, S.; Baumgärtner, W.: Evaluation of Measured Bridge Responses due to an Instrumented Truck and Free Traffic. Bridge Management Four, ed. Ryall, Parke, Hardening, Thomas Telford, London, 2000.
- [MaHS03] Mallot, H.A.; Hübner, W.; Stürzl, W.: Neuronale Netze. Erschienen in: Görz, G.; Rollinger, C.-R. und Schneeberger, J. (Hrsg.): Handbuch der Künstlichen Intelligenz. Oldenbourg-Verlag, 2003.
- [McPi43] McCulloch, W.S.; Pitts, W.: A Logical Calculus of the Ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics, Vol. 5, No. 4, S. 115-133, 1943.
- [MeHi06] Meystre, T.; Hirt, M.A.: Überprüfung bestehender Straßenbrücken mit aktualisierten Straßenlasten. Bundesamt für Straßen ASTRA, Abteilung Straßennetze (N), Bern, 2006.
- [MeSe95] Merzenich, G.; Sedlacek, G.: Hintergrundbericht zum Eurocode 1 – Teil 3.2: Verkehrslasten auf Straßenbrücken. Forschung Straßenbau und Straßenverkehrstechnik, Heft 711, Bonn, 1995.
- [MiPa69] Minsky, M.L.; Papert, S.A.: Perceptrons. Cambridge, MA: MIT Press, 1969.
- [Mitr02] Mitra, S.: Data Mining in Soft Computing Framework: A Survey. Erschienen in: IEEE Transactions on Neural Networks, Vol. 13, No. 1, S. 3-14, 2002.
- [Mose79] Moses, F.: Weigh-in-Motion System using Instrumented Bridges. ASCE, Transportation Engineering Journal, Vol. 105, No. 3, S. 233-249, 1979.
- [Muel03] Müller-Slany, H.H.: Möglichkeiten und Grenzen der Schwingungsdiagnose für mechanische Systeme auf der Basis numerischer Strukturmodelle. In VDI-Bericht 1788, S. 71-104, VDI-Schwingungstagung, 2003.
- [NaFH05] Naumann, J.; Friebel, W.-D.; Holst, R.: Bauwerksprüfung nach DIN 1076 – Eine verantwortungsvolle Aufgabe für die Sicherheit. Straße und Autobahn 56, S. 319-326, 2005.

- 
- [NaKK96] Nauck, D.; Klawonn, F.; Kruse, R.: Neuronale Netze und Fuzzy-Systeme. Vieweg & Sohn Verlagsgesellschaft/GWV Fachverlage GmbH, Wiesbaden, 1996.
- [Naum02] Naumann, J.: Die Brückenerhaltung ist für Ingenieure eine neue Herausforderung. Der Prüferingenieur, Ausgabe Oktober 2002, S. 46-52, 2002.
- [Naum06] Naumann, J.: Aktuelle Entwicklungen im Straßenbrückenbau. Stahlbau 75, S. 779-785, 2006.
- [Naum07] Naumann, J.: Brücken und Schwerverkehr – wo sind die Grenzen? Bauingenieur, Band 82, S. 25-29, Juli/August 2007.
- [NBBP07] Novák, B.; Brosge, S.; Barthel, K.; Pfisterer, W.: Anpassung des Verkehrslastmodells des DIN FB 101 für kommunale Brücken. Beton- und Stahlbetonbau 102, Heft 5, S. 271-279, 2007.
- [OpKu05] Opitz, R.; Kühne, R.: IM (Integrated Matrix) WIM Sensor and Future Trials. Tagungsband '4<sup>th</sup> International Conference on WIM', ICWIM4, Taipei, S. 61-71, 2005.
- [Peet00] Peeters, B.: System Identification and Damage Detection in Civil Engineering. Dissertation am 'Department of Civil Engineering', Katholische Universität Leuven, Belgien, ISBN 9056822748, 2000.
- [PeMD01] Peeters, B.; Maeck, J.; De Roeck, G.: Vibration-based Damage Detection in Civil Engineering: Excitation Sources and Temperature Effects. Smart Materials and Structures 10, S. 518-527, 2001.
- [PSFA03] Pullmann, T.; Skolicki, Z.; Freischlad, M.; Arciszewski, T.; De Jong, K.; Schnellenbach-Held, M.: Structural Design of Reinforced Concrete Tall Buildings: Evolutionary Computation Approach using Fuzzy Sets. In Ciftcioglu, Ö.; Dado, E. (Hrsg.): Intelligent Computing in Engineering, Foundation of Design Research SOON, S. 53-61, 2003.
- [PuSL07] Pullmann, T.; Schnellenbach-Held, M.; Lubasch, P.: GPCore – A Generic Framework for Genetic Programming. In: Proceedings of EG-ICE Conference, Maribor, 2007.
- [Rech73] Rechenberg, I.: Evolutionsstrategie: Optimierung Technischer Systeme nach Prinzipien der Biologischen Evolution. Frommann-Holzboog, Stuttgart, 1973.

- [RoCh04] Rojas Flores, J.E.; Chegury Viana, F.A.: Force Identification of Mechanical Systems by Using Particle Swarm Optimization. Tagungsband '10<sup>th</sup> AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference', Albany, New York, 2004.
- [Rose58] Rosenblatt, F.: The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review* 65 (6), S. 386-408, 1958.
- [RSRS05] Rücker, W.; Said, S.; Rohrmann, R.G.; Schmid, W.; Hille, F.; Mehdianpor, M.: Aufgaben der Dauerüberwachung und baulichen Bewertung am Beispiel von Betonbrücken und Windenergieanlagen. DAFStb Heft 565 (Hrsg.: Reinhardt, H.-W.): Zerstörungsfreie Prüfverfahren und Bauwerksdiagnose im Betonbau, 2005.
- [RuHW86] Rumelhart, D.E.; Hinton, G.E.; Williams, R.J.: Learning Representations by Back-Propagating Errors. *Nature* 323, S. 533-536, 1986.
- [SaBe05] Santa, U.; Bergmeister, K.: Zustandsüberwachung und Bewertung von Betontragwerken. *Beton- und Stahlbetonbau Spezial*, S. 82-88, 2005.
- [SaBS06] Samol, J.; Buschmeyer, W.; Schnellenbach-Held, M.: Zur Genehmigung von Schwertransporten. *Straßenverkehrstechnik* 50, S. 91-94, 2006.
- [SchHF96] Schöneburg, E.; Heinzmann, F.; Feddersen, S.: Genetische Algorithmen und Evolutionsstrategien – Eine Einführung in Theorie und Praxis der simulierten Evolution. Bonn, Paris: Addison-Wesley, 1996.
- [Schw81] Schwefel, H.-P.: Numerical Optimization of Computer Models. Wiley, 1981.
- [ScLB07a] Schnellenbach-Held, M.; Lubasch, P.; Buschmeyer, W.: Soft-WIM: Vehicle Identification from Bridge Measurement. In: *Proceedings of IABSE Conference*, Weimar, 2007.
- [ScLB07b] Schnellenbach-Held, M.; Lubasch, P.; Buschmeyer, W.: Erfassung der Verkehrsbelastung – die Brücke, die zählt. 50 Jahre Institut für Massivbau der Leibniz Universität Hannover, Band 5 (Hrsg: Grünberg, J.) Fraunhofer IRB Verlag, 2007.

- 
- [SDBF93] Spears, W.M.; De Jong, K.A.; Bäck, T.; Fogel, D.B.; De Garis, H.: An Overview of Evolutionary Computation. Tagungsband '6<sup>th</sup> European Conference on Machine Learning', ECML '93, S. 442-459, Springer, 1993.
- [SFAP04] Schnellenbach-Held, M.; Freischlad, M.; Albert, A.; Pullmann, T.; Lubasch, P.: Genetic Programming based Fuzzy System Design for Knowledge Representation in Structural Engineering. Schnellenbach-Held, M.; Hartmann, M. (Eds.): Next Generation – Intelligent Systems in Engineering, Proceedings of the 11<sup>th</sup> International EG-ICE Workshop, Fortschritt-Berichte VDI, Nr. 199, S. 120-127, Weimar, 2004.
- [Smit99] Smith, S.W.: The Scientist and Engineer's Guide to Digital Signal Processing. California Technical Publishing, San Diego, California, 1999.
- [Uhl02] Uhl, T.: Identification of Loads in Mechanical Structures – Helicopter Case Study. Computer Assisted Mechanics and Engineering Sciences, No. 9, S. 151-160, 2002.
- [Uhl07] Uhl, T.: The Inverse Identification Problem and its Technical Application. Archive of Applied Mechanics, Vol. 77, No. 5, S. 325-337, 2007.
- [UhPi01] Uhl, T.; Pieczara, J.: Applications of Genetic Algorithms for Identifications of Loads in Mechanical Structures. Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, AI-MECH 2001, S. 285-290, Gliwice, Polen, 2001.
- [UhPi03] Uhl, T.; Pieczara, J.: Identification of Operational Loading Forces for Mechanical Structures. Archives of Transport, Vol. 16, No. 2, S. 109-126, 2003.
- [VaHe05] Van Loo, H.; Henny, R.: REMOVE, Requirements for Enforcement of Overloaded Vehicles in Europe. Tagungsband '4<sup>th</sup> International Conference on WIM', ICWIM4, Taipei, S. 255-262, 2005.
- [VDA06] Verband der Automobilindustrie (VDA): Jahresbericht 2006. Frankfurt am Main, 2006.
- [Vesa02] Vesanto, J.: Data Exploration Process based on the Self-Organizing Map. Dissertation am 'Department of Computer Science and Engineering', Helsinki University of Technology, Finland, ISBN 9516665969, 2002.

- [WAVE01a] WAVE (Editor: Jacob, B.): Weigh-in-Motion of Axles and Vehicles for Europe (WAVE), General Report. 4<sup>th</sup> Framework Program Transport, RTD Project, RO-96-SC, 403, Paris, 2001.
- [WAVE01b] WAVE (Editors: O'Brien, E.; Žnidarič, A.): Weigh-in-Motion of Axles and Vehicles for Europe (WAVE), Report of Work Package 1.2, Bridge WIM Systems (B-WIM). 4<sup>th</sup> Framework Program Transport, RTD Project, RO-96-SC, 403, Dublin, 2001.
- [WeFV05] Wenzel, H.; Furtner, P.; Veit-Egerer, R.: DyGeS, Dynamisches Gewichtserfassungs-System. Endbericht im Forschungsförderungsprogramm „I2-Intelligente Infrastruktur“, Bundesministerium für Verkehr, Innovation und Technologie (BMVIT), Wien, 2005.
- [WeVe08] Wenzel, H.; Veit-Egerer, R.: Measurement based Traffic Loading Assessment of Steel Bridges – A Basis for Performance Prediction. International Journal of Structure and Infrastructure Engineering, 2008.
- [Whit01] Whitley, D.: An Overview of Evolutionary Algorithms: Practical Issues and Common Pitfalls. Information and Software Technology, Vol. 43, No. 14, S. 817-831, 2001.
- [WiHo60] Widrow, B.; Hoff, M.E.: Adaptive Switching Circuits. IRE Western Electric Show and Convention Record (WESCON), Teil 4, S. 96-104, 1960.
- [YaWS05] Yang, Y.W.; Wang, C.; Soh, C.K.: Force Identification of Dynamic Systems using Genetic Programming. International Journal for Numerical Methods in Engineering, Vol. 63, No. 9, S. 1288-1312, 2005.
- [Zade94] Zadeh, L.A.: Soft Computing and Fuzzy Logic. Software, IEEE, Vol. 11, No. 6, S. 48-56, 1994.
- [Zade01] Zadeh, L.A.: Applied Soft Computing – Foreword. Applied Soft Computing, Vol. 1, No. 1, S. 1-2, 2001.
- [Zell03] Zell, A.: Simulation Neuronaler Netze. 4. Auflage, Oldenbourg Verlag, München, 2003.
- [ŽnLK05] Žnidarič, A.; Lavrič, I.; Kalin, J.: Nothing-on-the-Road Axle Detection with Threshold Analysis. Tagungsband '4<sup>th</sup> International Conference on WIM', ICWIM4, Taipei, S. 85-96, 2005.

- [ZWSM06] Zhang, Y.; Wang, K.; Shaw, D.; Miles, J.; Parmee, I.; Kwan, A.: Representation and its Impact on Topological Search in Evolutionary Computation. Joint International Conference on Computing and Decision Making in Civil and Building Engineering, S. 2359-2368, Montreal, Canada, 2006.

